

Universidad de Buenos Aires  
Facultad de Ciencias Económicas  
Escuela de Estudios de Posgrado

---

**MAESTRÍA EN MÉTODOS CUANTITATIVOS PARA LA  
GESTIÓN Y ANÁLISIS DE DATOS EN  
ORGANIZACIONES**

---

**TRABAJO FINAL DE MAESTRÍA**

---

Las redes neuronales y la inversión publicitaria.  
Detección de puntos de contacto visual en video de  
comercial para la optimización de la visualización de  
la marca

Neural Networks and Advertising Investment:  
Detection of Visual Touchpoints in Commercial  
Videos for Brand Visualization Optimization

---

ALUMNO: EDGAR JOSÉ CORREA DIAZGRANADOS

DIRECTORA: MG. NATALIA ROMINA SALABERRY

JULIO 2024

---

## **Agradecimientos**

Agradezco sinceramente a Dios, quien me permitió culminar de manera satisfactoria esta etapa de mi vida, a mi directora Mg. Natalia Salaberry, por su guía constante, apoyo incondicional y valiosas correcciones que fueron fundamentales para el desarrollo y culminación de este trabajo.

A mi novia, Natalia Saoza Pico, le agradezco su paciencia, apoyo incondicional y comprensión durante este proceso, acompañándome en cada etapa, desde las largas noches de trabajo hasta las conversaciones sobre mi tesis, siempre dispuesta a escucharme y motivarme.

También deseo expresar mi profundo agradecimiento a mi familia: a mi padre, Edgar Correa Cerro, mi madre, Katy Diazgranados Montero y mi hermano, Cristhian Correa Diazgranados, quienes me brindaron las herramientas necesarias para completar mi pregrado y venir a Argentina en busca de nuevas oportunidades académicas y profesionales, siempre ayudándome a cumplir mis sueños. A mi tío Martin Correa Cerro, mi tía Farida Latif y mi tía Lina Correa Cerro, por su apoyo cuando lo necesite.

Por último, extendo mi gratitud a la Universidad de Buenos Aires y a cada uno de mis profesores y profesoras, cuya dedicación y conocimiento contribuyeron significativamente a mi formación académica y profesional.

## Resumen del proyecto

Las marcas buscan constantemente formas de mejorar su imagen ante la audiencia y maximizar la exposición de sus productos. Para lograrlo suelen invertir una cantidad significativa de recursos en publicidad y en *Product Placement*. Esta última técnica permite que las marcas sean incorporadas de manera sutil en el contenido audio visual, con el fin de mejorar su percepción por parte del espectador.

Recopilar información sobre la exposición de la colocación de productos se convierte en un desafío que es fundamental para las organizaciones ya que les permite optimizar la visualización de la marca en sus campañas publicitarias para mejorar su estrategia de *Marketing*. En este contexto, el presente trabajo final de maestría tiene por objetivo general elaborar un proceso de predicción mediante redes neuronales de la distancia entre la aparición de la marca PedidosYa y los puntos de contacto visual del espectador en el contexto de un comercial para optimizar la visualización de la marca.

Para alcanzar el objetivo planteado, el trabajo se estructura en tres capítulos. En el primer capítulo se aborda a las organizaciones basada en datos, destacando la importancia de las tecnologías de *Big Data* en el *Marketing* organizacional. En el segundo capítulo se especifica el análisis sobre datos no estructurados mediante la utilización de Redes Neuronales, en el contexto del *Product Placement*. Finalmente, en el tercer y último capítulo el análisis se centra en los puntos de contacto entre el *Product Placement* y los modelos para predecir la distancia entre estos y la aparición de la marca en un comercial como proceso para la optimización de la visualización.

De este modo, el trabajo contribuye al campo del *Marketing* de contenido al ofrecer una comprensión integral sobre la importancia de la gestión de datos no estructurados en la toma de decisiones estratégicas en organizaciones. Además, muestra cómo la recopilación, análisis y procesamiento de estos datos generan información relevante para el diseño de estrategias de *Product Placement*. Estas estrategias impactan directamente en la optimización de campañas publicitarias de colocación de productos, lo que a su vez conduce a una mejor gestión de la inversión en *Marketing*.

**Palabras claves:** Redes neuronales, Inversión publicitaria, Puntos de contacto visual, Video de comercial, Optimización de la visualización de la marca.

# Índice

<b><i>Agradecimientos</i></b> .....	2
<b><i>Resumen del proyecto</i></b> .....	3
<b><i>Introducción</i></b> .....	6
<b><i>Planteamiento del tema</i></b> .....	12
<b><i>Capítulo 1: Organizaciones basadas en datos y el uso de datos no estructurados en el Marketing</i></b> .....	13
Introducción.....	13
1.1. Organizaciones en una sociedad basada en datos.....	14
1.1.1. Caracterización de una organización basada en datos.....	16
1.1.2. Importancia de las Tecnologías de <i>Big data</i> para el análisis y la gestión organizacional.....	19
1.1.3. Generación de valor a través de la innovación y el <i>Big data</i> en una organización.....	23
1.2. Datos no estructurados en las organizaciones .....	25
1.2.1. Desafíos y oportunidades de los datos no estructurados .....	26
1.2.2. El rol de la gestión de datos no estructurados .....	29
1.3. <i>Marketing</i> organizacional basado en datos estructurados y no estructurados .....	31
1.3.1. <i>Product Placement</i> .....	33
1.3.2. Importancia de Medir la Exposición del <i>Product Placement</i> .....	34
Conclusiones.....	36
<b><i>Capítulo 2: Datos no estructurados en el Product Placement, recolección e información proporcionada</i></b> .....	37
Introducción.....	37
2.1. Datos preliminares del <i>Product Placement</i> .....	38
2.1.1. <i>Frames</i> .....	40
2.1.2. Píxeles.....	41
2.1.3. Colores.....	42
2.2. Metodología para la recolección de datos del <i>Product Placement</i> : Modelos de detección.....	44
2.2.1. Redes Neuronales como modelos de detección.....	45
2.2.2. Redes Neuronales Convolucionales .....	50
2.3. Información proporcionada por el modelo YOLOv5 .....	60
Conclusión.....	64
<b><i>Capítulo 3: Puntos de contacto en el Product Placement y modelos de optimización de la visualización</i></b> .....	66
Introducción.....	66
3.1. Detección de puntos de contactos en el <i>Product Placement</i> .....	68
3.1.1. Metodologías para la detección de puntos de contactos.....	69
3.1.2. Sincronización de puntos de contacto visual en consumidores.....	73
3.2. Modelos de clasificación para optimizar la visualización de la marca.....	78
3.2.2. <i>Decision Tree</i> .....	83
3.2.3. <i>Random Forest</i> .....	85
3.2.4. <i>Regresión logística</i> .....	87
3.2.5. <i>Regresión Logística con Grid Search</i> .....	88

3.3. Selección del mejor modelo y resultados del proceso de detección.....	90
3.3.1 Selección del modelo.....	91
3.3.2 Proceso de detección .....	94
Conclusión.....	96
<b>Conclusión .....</b>	<b>98</b>
<b>Referencias bibliográficas.....</b>	<b>103</b>
<b>Anexo .....</b>	<b>111</b>
Códigos aplicados.....	111

## Introducción

La publicidad se puede definir como el arte de convencer consumidores (Bassat, 2001); es utilizada por las organizaciones para promocionar sus productos o servicios a través de diversos medios, como la televisión, la radio, la prensa, el internet y las redes sociales (Castillo, 2015). Las agencias de medios suelen ser las encargadas de diseñar y ejecutar las estrategias de publicidad y *Marketing*, incluyendo la colocación de productos en programas de televisión, películas y otros medios (Belch *et al.*, 2014).

La colocación de productos (*Product Placement*) es una técnica de *Marketing* que consiste en la inclusión de un producto o marca en el contenido de una película, programa de televisión o videojuego. Según un estudio realizado por *PQ Media*, el gasto mundial en *Product Placement* alcanzó los 10,04 mil millones de dólares en 2019 (PQ Media, 2020). En comparación, el gasto global en publicidad superó los 600 mil millones de dólares ese mismo año (Statista, 2020), lo que implica que el gasto en *Product Placement* representó aproximadamente el 1,67% del total del gasto publicitario.

Aunque la inversión en *Product Placement* disminuyó en 2020 debido a la pandemia, se recuperó en 2021, registrando un aumento del 12,3% a nivel global y del 13,2% en Estados Unidos. En 2022, la inversión mundial en *Product Placement* según estimaciones de *PQ Media* alcanzó los 27,6 millones de dólares (casi el doble que en 2016) con un crecimiento global del 14,3% y, en Norteamérica, del 15,1%. Este notable crecimiento refleja la importancia del *Product Placement* como estrategia de *Marketing*.

De acuerdo con las cifras manejadas por *PQ Media*, el aumento de las acciones de *Product Placement* en los servicios de vídeo en *Streaming* está impulsando el crecimiento de esta fórmula publicitaria. El 62% de los usuarios de servicios de vídeo en *Streaming* de entre 18 y 34 años y el 66% de aquellos con edades comprendidas entre los 35 y los 49 años confiesan percatarse de la presencia de determinadas marcas y productos en los contenidos de estas plataformas. Una investigación de *YouGov* concluyó recientemente que en la cuarta temporada de la serie *Stranger Things*, el *Product Placement* se tradujo en un valor de 13,7 millones de dólares.

En un contexto donde la visualización tradicional de televisión ha disminuido y el consumo de medios se ha desplazado hacia plataformas digitales y servicios de contenido bajo demanda (Dolina, 2021), el *Product Placement* se ha adaptado eficazmente. A

diferencia de los anuncios publicitarios tradicionales, que pueden ser omitidos o bloqueados, el *Product Placement* tiene la ventaja de estar integrado de manera natural en el contenido, por lo que resulta menos intrusivo y más difícil de evitar. Además, puede estar presente en todos los medios, incluidos los digitales, lo que amplía su alcance y efectividad. Todas estas características, generan que la colocación de productos sea una estrategia de *Marketing* efectiva para muchas organizaciones resultando importante poder medir su exposición.

La exposición se refiere a la cantidad de veces que un producto o servicio aparece en un medio. Llevar a cabo su mesuramiento permite a las organizaciones entender la frecuencia y la duración de la aparición de sus productos o servicios (Yang y Roskos, 2007). También les facilita evaluar la efectividad de sus campañas de publicidad en comparación con otras técnicas de publicidad (Russell y Stern, 2006) así como entender el impacto de la colocación de productos en la percepción de la marca y en el comportamiento de compra de los consumidores (Balasubramanian, 1994).

Al mismo tiempo, realizar su medición es un desafío debido a su naturaleza integrada (d'Astous y Séguin, 1999). Esto se debe a las variaciones en la forma en que los productos se presentan en diferentes programas y películas (Russell y Stern, 2006), y a la falta de estándares uniformes en la industria (Law y Braun, 2000). Adicionalmente recopilar la información implica gestionar datos no estructurados. Gandomi y Haider (2015) definen los datos no estructurados (por ejemplo, videos) como aquellos datos que no se almacenan en una forma predefinida y organizada en una base de datos tradicional.

A pesar de estos desafíos, los investigadores y los profesionales del *Marketing* continúan desarrollando métodos para medir la colocación de productos y evaluar su efectividad en la publicidad. Uno de los métodos más comunes es el análisis visual. En este, los investigadores revisan grabaciones de programas y películas para identificar y registrar la presencia y la ubicación de la colocación de productos (Law y Braun, 2000). Para ello se valen del uso de software que les permite analizar los videos de manera más eficiente y precisa (Yang y Roskos, 2007).

Song *et al.* (2019) explican que los puntos de contacto visual (*Gaze Hits*) son una herramienta de análisis de video que permite a los investigadores identificar y medir la exposición de los productos. Por otra parte, Zhang *et al.* (2018), afirma que la utilización

de algoritmos como YOLO (*You Only Look Once*) permite identificar y rastrear la presencia de productos específicos en los programas de televisión. YOLO es una técnica de detección de objetos en imágenes que utiliza redes neuronales convolucionales (CNN<sup>1</sup>). Las CNN son un tipo específico de red neuronal que se utiliza principalmente para el procesamiento de imágenes y el reconocimiento visual. Están diseñadas para detectar patrones en las imágenes y extraer características relevantes automáticamente.

Las CNN están compuestas por capas de nodos (neuronas) interconectados que procesan información y detectan patrones en las imágenes, extrayendo características relevantes de manera automática. Una red neuronal es un modelo computacional inspirado en el funcionamiento del cerebro humano que permite aprender y reconocer patrones complejos en los datos. La exposición a más datos y retroalimentación mejoran su precisión (Goodfellow, 2016).

La elección del tema a tratar para la elaboración de la tesis de maestría de Métodos Cuantitativos para la Gestión y Análisis de Datos en Organizaciones se considera de interés para las diferentes organizaciones, en la medida que se busca elaborar un proceso de modelado que combine puntos de contacto y CNNs para medir de forma eficiente la exposición de la colocación de productos en comerciales audio visual. El mismo, tendrá en cuenta características del video, como color, tamaño y aparición de marca, así como los puntos de contacto entre el ojo del espectador y el producto en la imagen.

Como resultado, las organizaciones podrán contar con mayor cantidad de información sobre sus campañas publicitarias lo que les brinda la posibilidad de tomar decisiones basadas en datos. Por otra parte, se considera que la temática se encuentra incluida en el campo de estudio de la maestría, ya que aborda aspectos relacionados con el procesamiento automatizado de datos no estructurados y su gestión.

En este contexto, el presente trabajo final de maestría tiene por objetivo general elaborar un proceso de predicción mediante redes neuronales de la distancia entre la aparición de una marca y los puntos de contacto visual del espectador en un comercial de televisión y de este modo optimizar la visualización. Este será abordado a través de tres objetivos específicos. El primero, es comprender la relevancia de la gestión de datos no estructurados en la toma de decisiones en las organizaciones que invierten en colocación

---

<sup>1</sup> CNN significa *Convolutional Neural Network* (Red Neuronal Convolucional en español)

de productos. El segundo, es identificar cómo las redes neuronales permiten llevar a cabo la medición automatizada de la exposición de la colocación de productos en un comercial de televisión. Finalmente, el tercero es definir un proceso con la capacidad de predecir la distancia entre la aparición de la marca PedidosYa y los puntos de contacto visual del espectador para optimizar la visualización de la marca. Para el cumplimiento de cada uno de ellos, la realización del trabajo se organiza en tres capítulos.

En el primer capítulo, el objetivo a desarrollar consiste en evaluar la relevancia y el impacto de la gestión de datos no estructurados en la toma de decisiones de organizaciones que implementan estrategias de colocación de productos basadas en datos. La hipótesis asociada es que una gestión efectiva de datos no estructurados en organizaciones que implementan estrategias de colocación de productos basadas en datos conducirá a una mejora significativa en la precisión y efectividad de las decisiones tomadas. Esto, a su vez, se traducirá en un aumento de la visualización y en la optimización de las estrategias de *Marketing* implementadas. La caracterización de las organizaciones basadas en datos y el análisis de la importancia de las tecnologías de *Big Data* para la gestión organizacional proporcionan un contexto sólido para comprender cómo este tipo de organizaciones dependen cada vez más de datos estructurados y no estructurados para tomar decisiones estratégicas.

Además, al explorar los desafíos y oportunidades asociados con los datos no estructurados, se evidencia la necesidad de una gestión eficaz de estos para aprovechar su potencial en la generación de valor para la organización. En el contexto del *Marketing* organizacional, se destaca la relevancia del *Product Placement* como una estrategia de ese tipo para la generación de valor, donde la medición precisa de la exposición de productos se convierte en un factor crítico para evaluar su efectividad. De este modo, los aspectos mencionados proporcionan el fundamento teórico y conceptual para una primera aproximación para sustentar la hipótesis planteada.

El segundo capítulo, tiene por objetivo evaluar cómo el procesamiento de datos no estructurados facilita la generación de información relevante para el diseño de estrategias de colocación de productos. La hipótesis aquí planteada es que la implementación de modelos de detección para la recopilación, análisis y procesamiento de datos no estructurados contribuye significativamente a la generación de información relevante para el diseño de estrategias de *Product Placement* en organizaciones. En este capítulo,

primero se exploran los datos preliminares del *Product Placement*, como los *frames*, los píxeles y los colores, lo que proporciona una comprensión básica de los elementos esenciales para la identificación de productos en contenido audiovisual. Este conocimiento preliminar es crucial para el posterior análisis de la presencia y exposición de los productos.

Luego, se profundiza en la metodología para la recolección de datos mediante Redes Neuronales y Redes Neuronales Convolucionales. Estos modelos permiten identificar y extraer información relevante de grandes volúmenes de datos no estructurados, lo que constituye una base sólida para la generación de información relevante en el diseño de estrategias de *Product Placement*. Por último, se examina específicamente la información obtenida a través del modelo YOLOv5. Este análisis detallado de la metodología y los modelos de detección utilizados proporciona una comprensión más profunda de cómo el adecuado manejo de los datos no estructurados mediante modelos de detección puede contribuir a la generación de información relevante para el diseño de estrategias de *Product Placement* en organizaciones. En conjunto, estos métodos permiten un primer acercamiento a la hipótesis planteada.

En el tercer y último capítulo, el objetivo es analizar cómo optimizar la visualización de la marca en el *Marketing* de contenido a través de la predicción de la distancia entre la colocación del producto y los puntos de contacto visual. La hipótesis asociada es que la utilización de un modelo de clasificación óptimo para predecir la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual, permite maximizar la visualización de la marca en el *Marketing* de contenido. Para ello, se exploran dos aspectos principales: la detección de puntos de contacto en el *Product Placement* y los modelos de clasificación para optimizar la visualización.

Para abordar la detección de puntos de contacto en el *Product Placement*, se aplican diferentes modelos de clasificación (KNN, *Decision Tree*, *Random Forest*, Regresión logística y Regresión Logística con *Grid Search*) con el fin de predecir la distancia entre el punto medio de contacto visual y la detección de la marca. Estos modelos representan diferentes enfoques para predecir la distancia mencionada. Al evaluar la eficacia de cada uno, se seleccionará el más adecuado para maximizar la visualización de la marca.

Finalmente, para optimizar la visualización se lleva a cabo la selección del mejor modelo y se presentan los resultados del proceso de detección. Esto implica identificar el modelo de clasificación óptimo que ofrece la mayor precisión y efectividad en la predicción de la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual. En conjunto, los resultados obtenidos permiten una adyacencia inicial a la hipótesis planteada sobre cómo el uso de un modelo de clasificación óptimo puede contribuir a maximizar la visualización de una marca en el *Marketing* de contenido a través de una predicción precisa y en específico.

Tras la consecución de los objetivos planteados en cada capítulo, este trabajo ofrece un avance considerable en el campo del *Marketing* de contenido. A través de un enfoque cualitativo y cuantitativo, estructurado y detallado, el trabajo proporciona una metodología para la comprensión integral de la gestión de datos no estructurados, la influencia de la recopilación y análisis de datos en estrategias de *Product Placement*, y la optimización de la visualización en el *Marketing* de contenido. Estos hallazgos representan un punto de partida fundamental para el diseño e implementación de estrategias efectivas de *Marketing* de contenido basadas en datos, tanto en el ámbito académico como en el organizacional.

## **Planteamiento del tema**

En las estrategias publicitarias de *Product Placement*, las marcas pagan por la inclusión de sus productos en contenidos audiovisuales con la expectativa de obtener la mayor rentabilidad posible. El costo de esta inversión depende principalmente de dos factores: la cantidad de tiempo que el producto aparece en pantalla y la popularidad del programa en el que se presenta. Sin embargo, las entidades que emiten los programas suelen proporcionar un tiempo estimado de aparición en pantalla, ya que carecen de las herramientas para medir y mostrar el tiempo real de exposición. Actualmente, con los avances en visión por computadora, es posible medir de manera más precisa la exposición del producto, es decir, cuánto tiempo se ha visto en pantalla y en qué contexto.

El presente trabajo busca determinar un proceso en base a datos no estructurados para medir el tiempo exacto de exposición y de atención a una marca en particular que aparece en un comercial de televisión con el fin de optimizar la visualización. A partir de un video de un comercial de PedidosYa de duración corta, luego se podrá utilizar para cualquier marca y en videos de mayor duración. La elección del mencionado comercial se debe a que es una marca conocida, fácil de recordar y además invierte en la colocación de productos.

En este contexto la pregunta de investigación que busca responder el presente trabajo es: ¿Cómo se puede optimizar la visualización de la marca PedidosYa en la colocación de productos, utilizando puntos de contacto visual y Redes Neuronales? Para poder responder este interrogante, el objetivo general de la tesis es elaborar un proceso de predicción mediante redes neuronales de la distancia entre la aparición de la marca PedidosYa y los puntos de contacto visual del consumidor en un comercial de televisión y optimizar su visualización. La hipótesis general asociada es que la gestión y análisis de datos no estructurados en organizaciones que invierten en la colocación de productos permite tomar decisiones que repercuten de manera positiva en la visualización de la marca.

Como objetivos específicos se considera comprender la relevancia de la gestión de datos no estructurados en la toma de decisiones en las organizaciones que invierten en colocación de productos, identificar cómo las redes neuronales permiten llevar a cabo la medición automatizada de la exposición de la colocación de productos en un comercial de televisión y, finalmente, definir un proceso con la capacidad de predecir la distancia

entre la aparición de la marca PedidosYa en el comercial y los puntos de contacto visual del espectador para optimizar la visualización.

## **Capítulo 1: Organizaciones basadas en datos y el uso de datos no estructurados en el *Marketing***

### **Introducción**

Las organizaciones contemporáneas se encuentran inmersas en un entorno donde la información representa un recurso vital. En este sentido, la evolución hacia organizaciones basadas en datos se ha convertido en un pilar fundamental para la toma de decisiones estratégicas y la optimización de procesos internos (Chen *et al.*, 2012). En este entorno, el *Marketing* ha experimentado una transformación significativa al incorporar datos no estructurados, que abarcan desde interacciones en redes sociales hasta análisis de videos y seguimiento de tendencias. La integración de estos datos no estructurados en las estrategias de *Marketing*, como la colocación de productos ha propiciado una comprensión más holística y profunda del comportamiento del consumidor, permitiendo a las organizaciones adaptar sus enfoques para satisfacer de manera más precisa las demandas de los consumidores (Jeffery, 2010).

El *Marketing* ha evolucionado, aprovechando la diversidad y complejidad de los datos no estructurados para obtener una visión más completa del público objetivo (Blattberg, 2008). El análisis de estos datos, provenientes de múltiples fuentes como vídeos, imágenes, comentarios en redes sociales o reseñas en línea, permite a las organizaciones detectar patrones, tendencias y preferencias que son fundamentales para la creación de estrategias de *Marketing* más efectivas y personalizadas. La capacidad de las organizaciones para aprovechar estos datos no estructurados en la colocación de productos en el entorno del *Marketing* ha llevado a un cambio significativo en la forma en que se comprende, se interactúa y se llega a los consumidores en el mercado actual, impulsando así un enfoque más centrado en la experiencia del cliente y en la adaptación dinámica a las necesidades cambiantes del mercado (Bauer, 2000).

En este contexto, surge la siguiente pregunta: ¿Cuál es la relevancia y el impacto de la gestión de datos no estructurados en la toma de decisiones en organizaciones que implementan estrategias de colocación de productos basadas en datos? Con el propósito de responder este interrogante, el objetivo del presente capítulo se enfoca en explorar la

naturaleza de una organización en una sociedad basada en datos, analizar el papel que juegan los diferentes tipos de datos y, especialmente, examinar cómo se lleva a cabo el proceso de toma de decisiones en el ámbito del *Marketing* organizacional.

Con el fin de lograr especificar sobre organizaciones que implementan estrategias de colocación de productos basadas en datos, el presente capítulo se divide en tres secciones. En la primera sección se desarrolla la conceptualización de una organización basada en datos. Luego, se desarrolla una definición a partir de tres dimensiones claves: sus características, las tecnologías de *Big Data*, y la generación de valor.

En la segunda sección, se ahonda en las características particulares de los datos no estructurados. En un primer apartado, se exploran tanto los desafíos inherentes como las oportunidades que estos datos ofrecen a las organizaciones. Luego, se profundiza en el papel desempeñado por este tipo de datos en el contexto del *Marketing* organizacional, destacando su influencia en la conformación de estrategias en el sector. Finalmente, la tercera sección se centra en el concepto de *Marketing* organizacional basado en datos. Aquí, se analiza el *Product Placement* como una de las manifestaciones de este enfoque y se examina la importancia crucial de medir su tiempo de exposición como factor determinante en la eficacia de las estrategias de *Marketing*.

### **1.1. Organizaciones en una sociedad basada en datos**

Una sociedad es un conjunto de individuos que se relacionan entre sí, comparten normas, valores, formas de organización y colaboran para alcanzar metas comunes (Macionis y Plummer, 2012). Cuando una sociedad comparte objetivos, se impulsa a evolucionar constantemente para mejorar la calidad de vida de sus miembros. Esta evolución puede verse reflejada por ejemplo en la creación y desarrollo de las Tecnologías de la Información y la Comunicación (*TIC*), las cuales desempeñan un papel fundamental en la transformación y progreso de la sociedad (Castells, 2006).

Las *TIC* son un conjunto de herramientas, procesos y sistemas tecnológicos que se utilizan para recopilar, almacenar, procesar, transmitir y presentar información (García *et al.*, 2002). Incluyen tecnologías y dispositivos como computadoras, teléfonos móviles, internet, redes de comunicación, *softwares*, aplicaciones móviles, sistemas de gestión de bases de datos, entre otros. Se utilizan en diversos ámbitos, incluyendo el sector empresarial, la educación, la salud, el gobierno, la publicidad y la sociedad en general. Se

han convertido en una herramienta clave para la comunicación, la colaboración, la innovación y la mejora de la eficiencia y productividad (Castells, 2004).

La evolución de estas tecnologías durante el siglo XXI ha dado lugar a lo que se conoce como una sociedad impulsada por datos (*Data Driven Society*). Esta es una sociedad “modelada por datos” (Mayer-Schönberger y Cukier, 2013), es decir, aquella en la cual el procesamiento de datos para la generación de información se encuentra en el núcleo de su economía, política, cultura y organización social (Kitchin, 2014). De este modo, la nueva configuración social se refiere a una cultura en la que la información está en el centro de la toma de decisiones y la innovación.

La configuración social de esta era modelada por datos, no sólo se limita al ámbito de la toma de decisiones y la innovación. También se extiende a través de múltiples aspectos de la vida cotidiana, transformando la manera en que interactuamos, consumimos y nos relacionamos entre nosotros y con las instituciones (Castells, 2006). Esta revolución, cuyo centro son los datos, ha creado una sociedad en la que la información no solo influye en la esfera de los negocios y la gobernanza, sino que también redefine la identidad cultural y la autonomía individual (Mayer-Schönberger y Cukier, 2013). Se configura así un entorno donde la capacidad de acceder, comprender y utilizar datos se convierte en un determinante crucial de la inclusión social y la igualdad de oportunidades. A su vez, viene acompañado de desafíos éticos y de privacidad que deben ser abordados para garantizar una coexistencia equitativa y sostenible en esta nueva era *Data-Driven* (Kitchin, 2014).

El impacto causado por la revolución *Data-Driven* ha cambiado la forma en que las organizaciones y los individuos operan y se relacionan entre sí. Esto ha dado lugar al surgimiento de un nuevo tipo de organización que basa sus decisiones en datos (*Data Driven Organizations*). A diferencia de una organización clásica, caracterizada por seguir estructuras jerárquicas y procesos tradicionales en su toma de decisiones y operaciones (Haskel y Westlake, 2017), este nuevo tipo se fundamenta en la recopilación, análisis y utilización de datos en todas las áreas de su funcionamiento (McAfee y Brynjolfsson, 2012). En este sentido, las decisiones se toman basándose en evidencias lo que permite alcanzar una mayor precisión y eficiencia.

Las organizaciones basadas en datos realizan inversiones significativas en *TIC* avanzadas, sistemas de gestión de bases de datos, análisis de datos, inteligencia artificial y

aprendizaje automático. Tales herramientas y tecnologías permiten a las organizaciones extraer información valiosa de los datos, descubrir nuevas perspectivas y tomar decisiones fundamentadas (Bughin *et al.*, 2010). Así, cada una de estas inversiones juega un papel fundamental en las características que define a este tipo de organización.

Con el objetivo de comprender cómo se genera valor en las organizaciones *Data Driven*, en el presente capítulo se analizarán las principales características y se destacará el rol central del *Big Data*. En la primera sección, se abordará detalladamente las características particulares de este tipo de organizaciones. A continuación, se explorará el concepto de *Big Data*, como un conjunto de tecnologías digitales para la generación de información. Finalmente, a partir de lo anterior, se explicará como el dato pasa a ser un recurso fundamental en dichas organizaciones.

### **1.1.1. Caracterización de una organización basada en datos**

En el contexto actual de *Data Driven Societies*, las *Data Driven Organizations* se definen por su capacidad para fomentar una cultura sólida en torno a la información. Este enfoque cultural se erige como un pilar fundamental para el funcionamiento de estas. La accesibilidad a los datos se convierte en una premisa crucial dentro de esta cultura, garantizando que todos los miembros de la organización, sin importar su rol o nivel jerárquico, puedan obtener y emplear información de manera eficiente (Davidaviciene y Al, 2022).

La cultura organizacional basada en datos fomenta la transparencia y la colaboración, impulsando así la toma de decisiones fundamentada en la información disponible (Gartner, 2012). Su conexión con la gestión de datos radica en que promueve una mentalidad orientada a utilizar información precisa y relevante para la consecución de los objetivos organizacionales. En este sentido, la gestión de grandes volúmenes de datos se convierte en un desafío clave para estas organizaciones, dado el constante aumento exponencial de la información disponible (Schönberger y Cukier, 2013). De esta manera, la cultura de datos dentro de una organización proporciona el marco necesario para la gestión efectiva de datos a gran escala. Esta cultura no solo involucra la accesibilidad a la información, sino que también implica la promoción de la comprensión y el valor de los datos en todos los niveles de la organización, facilitando así la toma de decisiones informadas y estratégicas.

A su vez, el enfoque de la cultura de datos impulsa la igualdad de oportunidades y previene la concentración de información en un selecto grupo de individuos o departamentos. Esta forma de democratización posibilita la participación de todos los empleados en la generación de ideas, la resolución de problemas y la identificación de oportunidades de mejora (Brown y Hagel, 2012). Además, facilita la detección temprana de patrones y tendencias, así como oportunidades de negocio. Teniendo en cuenta que los datos están a disposición de todos, éstos pueden ser analizados desde diversas perspectivas, lo que fomenta la generación de ideas innovadoras y estrategias más efectivas.

Para lograr la democratización propuesta por la cultura de datos, las organizaciones deben establecer una infraestructura sólida de tecnología de la información, incluyendo una estructura de datos robusta y una arquitectura de sistemas de tecnología de la información (Gartner, 2012). Estos elementos facilitan la recopilación, el almacenamiento, el procesamiento y el análisis de volúmenes masivos de datos (Rainer *et al.*, 2017). Además, los sistemas de información agilizan la gestión y el acceso a los datos. Como señalan Vidal *et al.* (2018), “la gestión de información abarca una serie de procesos, políticas y prácticas que permiten adquirir, organizar, almacenar, proteger y emplear información de manera eficiente y efectiva” (p. 123). Una gestión de datos efectiva resulta esencial para garantizar la precisión y la confiabilidad de la información, así como para asegurar un uso óptimo de los datos (Chen *et al.*, 2012). Esto, a su vez, requiere de la utilización de herramientas y técnicas de análisis de datos, así como la integración de diversas fuentes de información.

Una gestión eficiente de la información asegura que los datos estén disponibles cuando se necesiten y en el formato adecuado, empoderando a la organización para tomar decisiones informadas y maximizar su potencial. Además, desempeña un papel esencial en la seguridad y protección de los datos. Según Raghupathi (2014), “una gestión adecuada de la información implica medidas de seguridad y privacidad para resguardar los datos contra accesos no autorizados, preservando su confidencialidad e integridad” (p. 67). Este aspecto cobra particular importancia en una sociedad basada en datos, donde la confianza y la protección de la información resultan fundamentales para mantener la credibilidad y cumplir con las regulaciones.

La toma de decisiones informadas implica la adopción de decisiones objetivas fundamentadas en información fidedigna y precisa, en lugar de depender de conjeturas o prejuicios. A su vez, la toma de decisiones respaldada por datos no solo fortalece la innovación, sino también fomenta la experimentación al permitir una evaluación basada en datos de los resultados obtenidos (Mayer-Schönberger y Cukier, 2013). Complementando esta noción, la efectiva administración del talento se erige como un pilar ineludible en una organización orientada hacia los datos. Esto implica seleccionar, retener y desarrollar empleados con destrezas y conocimientos en análisis de datos y tecnología de la información. Un aspecto crucial aquí es asegurar que las personas de la organización cuenten con las competencias necesarias para una gestión y análisis eficaces de datos, así como para fundamentar las decisiones en información sólida (Chen *et al.*, 2012).

Dentro del paradigma de la organización centrada en datos, surge la orientación al cliente como característica primordial, adquiriendo un rol central en la estrategia. Este enfoque, radica en comprender y satisfacer las necesidades y preferencias del cliente, lo cual es posible de lograr a través del análisis de datos (Westerman *et al.*, 2014). El análisis de datos implica aprovechar los datos para obtener una comprensión profunda del cliente, incluyendo patrones de compra, preferencias, opiniones y requerimientos. Esto otorga a la organización la capacidad de personalizar productos, servicios y estrategias de *Marketing* de acuerdo con las necesidades específicas de cada cliente.

Los datos actúan como representaciones de los individuos y contienen información valiosa sobre sus preferencias, comportamientos y necesidades (Salaberry, 2022). La conversión de los datos en información facilita una comprensión más profunda de los individuos, sus características y sus interacciones, impulsando así la toma de decisiones informadas y la mejora continua de productos, servicios y experiencias. Para ello se necesita obtener y transformar los datos ya que estos son generados en los diferentes canales digitales de la organización.

En el proceso de obtención y transformación de datos, la tecnología aplicada a la gestión y análisis de datos se vuelve fundamental. Las tecnologías dedicadas a manejar grandes volúmenes de información desempeñan un rol esencial al simplificar y agilizar la generación de conocimiento para respaldar la toma de decisiones estratégicas (Constantiou y Kallinikos, 2015). Estas herramientas permiten no sólo el almacenamiento

eficiente de datos, sino también su procesamiento y análisis, lo que resulta crucial para extraer información valiosa y significativa para la organización. Su importancia radica en la capacidad de estas tecnologías para proporcionar perspectivas detalladas sobre clientes, operaciones y mercados, lo que a su vez alimenta la toma de decisiones informadas.

En particular, las tecnologías de *Big Data* desempeñan un papel esencial al simplificar y agilizar la generación de conocimiento para respaldar la toma de decisiones (Constantiou y Kallinikos, 2015). Para comprender como permiten construir conocimiento, en el siguiente apartado se profundiza sobre el concepto de *Big Data* y su importancia.

### **1.1.2. Importancia de las Tecnologías de *Big data* para el análisis y la gestión organizacional**

En el contexto de las organizaciones orientadas hacia datos, el concepto de *Big Data* ocupa un rol central al influir en la toma de decisiones, la optimización de procesos y la generación de ventajas competitivas (Gartner, 2012). En esencia, el término hace referencia a conjuntos de datos vastos y complejos que requieren enfoques y herramientas especializadas para su gestión y análisis. Estos datos se caracterizan por cuatro dimensiones cruciales, conocidas como las 4V del *Big Data* (Laney, 2001): volumen, velocidad, variedad y veracidad.

En cuanto a Volumen, se hace referencia al volumen masivo de información como resultado de los avances tecnológicos. Esto permite acumular y procesar cantidades inimaginables de datos, lo que al mismo tiempo plantea desafíos en infraestructura, capacidad de procesamiento y análisis (Manyika *et al.*, 2011). A esta complejidad se suma la velocidad vertiginosa con la que los datos son generados y procesados en tiempo real, exigiendo soluciones tecnológicas ágiles (Laney, 2001). La variedad de datos se refiere a la diversidad de fuentes de las que provienen los datos, redes sociales, sensores y transacciones financieras, entre otras, que complica el almacenamiento y análisis tradicional, requiriendo herramientas para manejar su diversidad (Mayer-Schönberger, 2013). La fiabilidad y precisión de los datos adquieren una dimensión aún más crucial en el contexto del *Big Data*, donde la variedad y la velocidad de generación de información desafían la capacidad de las organizaciones para procesarla de manera efectiva.

La confiabilidad de los datos se convierte en un pilar fundamental, ya que las decisiones se basan en conjuntos de información cada vez más extensos y diversos. Como señala

Kitchin (2014), en este entorno de múltiples fuentes de datos, la veracidad se convierte en un desafío clave, dado que la integración de datos heterogéneos puede llevar a inconsistencias y errores, lo que a su vez puede comprometer la integridad de las decisiones basadas en ellos. Por ende, la garantía de la precisión y confiabilidad de los datos se vuelve imprescindible para asegurar que los resultados del análisis sean sólidos y las decisiones empresariales estén fundamentadas en información precisa y verídica.

Además, en el ecosistema del *Big Data*, la precisión y confiabilidad de los datos no sólo influyen en la toma de decisiones empresariales, sino también en aspectos éticos y legales. Según Mayer-Schönberger y Cukier (2013), la confiabilidad de los datos adquiere una relevancia significativa en términos de privacidad y protección de datos, donde la integridad y veracidad de la información son fundamentales para cumplir con regulaciones y proteger la información sensible de los usuarios. La incertidumbre en los datos puede llevar a consecuencias legales adversas y erosionar la confianza de los clientes, lo que pone de manifiesto la necesidad de implementar medidas robustas de control de calidad y validación de datos en el análisis de *Big Data*.

Es importante subrayar que estas cuatro dimensiones (4V) del *Big Data* no fluctúan en función del tipo de organización (IDC, 2012). Estas características se mantienen fundamentales y aplicables de manera universal en el contexto del *Big Data*, sin importar la industria ni el tipo de organización. No obstante, la forma en que las organizaciones gestionan y analizan los datos puede variar en función de sus necesidades y objetivos específicos, lo que a su vez puede ser influido por la industria a la que pertenecen.

La trascendencia del *Big Data* para las organizaciones se destaca como un elemento fundamental. La creciente cantidad de datos generados y recopilados en la sociedad no sólo presenta desafíos logísticos, sino también oportunidades inéditas. Esta avalancha de información masiva emerge como un recurso inexcusable que puede transformar la manera en que las organizaciones toman decisiones estratégicas, potencian su eficiencia operativa e impulsan la innovación en todos los niveles (Schmarzo, 2013). Es en este escenario que el *Big Data* se convierte en una herramienta esencial para el análisis inteligente de datos, permitiendo a las organizaciones identificar patrones y tendencias significativas que podrían pasar inadvertidos en conjuntos de datos más limitados (Chen *et al.*, 2014).

El análisis inteligente de datos masivos no sólo implica la capacidad de procesar grandes volúmenes de información, sino también la habilidad para extraer perspectivas valiosas y relevantes de dichos datos. Esta capacidad de identificar patrones ocultos y tendencias emergentes puede arrojar luz sobre el comportamiento del cliente, mejorar la eficiencia operativa y ofrecer una comprensión más profunda del rendimiento global de la organización. El análisis inteligente no se limita solo a la manipulación de datos, sino que se centra en el descubrimiento de información significativa que pueda fundamentar decisiones estratégicas sólidas y precisas para el crecimiento y desarrollo empresarial en un mundo impulsado por datos masivos (Chen *et al.*, 2014).

La intersección entre el análisis inteligente de datos masivos y la toma de decisiones informadas representa un componente crucial en el contexto del *Big Data*. Según Rhodes y Lancaster (2019), esta conexión es fundamental, ya que el análisis riguroso de datos masivos no sólo permite la identificación de patrones significativos, sino que también posibilita la generación de información clave para respaldar decisiones fundamentadas. En este sentido, las tecnologías asociadas al *Big Data* juegan un papel vital al facilitar la convergencia de estos dos aspectos fundamentales.

Las tecnologías del *Big Data* actúan como el puente entre el análisis de datos masivos y la toma de decisiones informadas (Rhodes y Lancaster, 2019). Permiten no solo la recolección y el almacenamiento eficiente de grandes volúmenes de información, sino también su procesamiento y análisis avanzado. Es a través de este análisis que se pueden descubrir patrones, tendencias y correlaciones significativas en los datos, proporcionando así información valiosa para respaldar la toma de decisiones estratégicas y fundamentadas dentro de una organización.

La adopción de decisiones basadas en datos masivos permite a las organizaciones detectar tendencias emergentes y anticipar riesgos, lo que reduce la incertidumbre y minimiza posibles pérdidas. Al analizar datos, las empresas optimizan estrategias, mejoran la eficiencia operativa y ofrecen experiencias personalizadas, maximizando así oportunidades de negocio y la satisfacción del cliente. Esta aproximación fundamentada en evidencia conlleva una reducción de riesgos y una maximización de oportunidades, lo que fortalece la posición competitiva de las organizaciones en entornos de datos masivos.

Asimismo, el *Big Data* promueve una mayor agilidad en la toma de decisiones. Gracias a la capacidad de procesar y analizar datos en tiempo real, las organizaciones pueden responder de manera inmediata a cambios en el mercado, ajustar estrategias y operaciones en función de tendencias emergentes y tomar medidas preventivas ante posibles problemas. Esta agilidad es esencial en un entorno empresarial caracterizado por la velocidad y la volatilidad. La optimización de procesos genera una mayor agilidad y esta es una faceta fundamental por la cual el *Big Data* potencia a las organizaciones. Al analizar minuciosamente los datos generados en cada etapa de un proceso, las organizaciones pueden identificar ineficiencias, cuellos de botella y áreas de mejora. Estos *insights* permiten implementar ajustes precisos y, en última instancia, mejorar la eficiencia operativa y reducir costos (Chen, 2014).

En la dinámica continua por alcanzar ventajas competitivas, el *Big Data* se manifiesta como un recurso de inmenso valor. Al sumergirse en la segmentación y análisis de datos, las organizaciones obtienen una comprensión profunda de las preferencias y necesidades de los clientes, lo que les permite adaptar de manera personalizada sus productos, servicios y estrategias de *Marketing*. Esta capacidad de ajuste a las exigencias cambiantes del mercado no sólo marca la diferencia entre el éxito y el estancamiento, sino que, además, constituye un factor determinante para mantener una posición líder en la industria (Schmarzo, 2013).

De esta manera, los datos adquieren una relevancia crucial en el contexto del *Big Data* dentro de las organizaciones, convirtiéndose en activos invaluable. A pesar de ser intangibles, el valor y la utilidad de los datos son innegables (Haskel y Westlake, 2017). Esta percepción se ve reforzada por la comprensión de que, además de los datos mismos, existe un capital esencial para generar valor en una organización orientada a los datos, un capital igualmente intangible. Este activo fusiona conocimientos, habilidades y aptitudes indispensables para la recolección, análisis y aprovechamiento eficaz de los datos, respaldado por recursos como sistemas informáticos avanzados, servidores eficientes y personal altamente especializado. Este conjunto de elementos amalgamados conforma un activo invaluable que impulsa la capacidad de las organizaciones para competir y prosperar en el entorno actual, generando valor.

### **1.1.3. Generación de valor a través de la innovación y el *Big data* en una organización**

La generación de valor en las organizaciones basadas en datos es un proceso intrincado que involucra la capacidad de transformar los datos en beneficios tangibles y estratégicos (Schmarzo, 2014). Esta se sustenta en la innovación como eje fundamental, aprovechando las características distintivas de este tipo de organizaciones. Estas entidades se distinguen por su capacidad para recopilar, analizar y emplear eficazmente grandes volúmenes de datos (Hupperz, 2021).

La innovación en este contexto no solo se limita a la búsqueda de nuevas tecnologías o métodos, sino que también abarca la aplicación creativa y estratégica de estos datos para generar soluciones novedosas y ventajas competitivas. La utilización innovadora del *Big Data*, con su capacidad para manejar la gran cantidad de información, se vuelve esencial en la búsqueda de *insights* valiosos y patrones significativos que impulsen la toma de decisiones estratégicas (Bughin *et al.*, 2010). Las organizaciones basadas en datos aprovechan la innovación para transformar la información en un activo estratégico.

Esta mentalidad innovadora no solo impulsa la adopción de tecnologías avanzadas y enfoques analíticos vanguardistas para comprender mejor a los clientes, optimizar procesos internos y anticipar tendencias emergentes en el mercado, sino que también se refleja en la capacidad de innovar en la gestión y análisis de datos. La capacidad de innovación se traduce en una mejor adaptación a los cambios del entorno, facilitando respuestas ágiles y estratégicas que se reflejan directamente en la creación de valor (Schmarzo, 2014).

Dentro de este enfoque innovador, la construcción de relaciones sólidas con los clientes es un pilar fundamental. La comprensión profunda de los datos del cliente no solo permite a las organizaciones personalizar las experiencias y brindar un servicio excepcional, sino que también les otorga la capacidad de anticipar sus necesidades futuras. La fidelización de los clientes a través de la atención personalizada y una comunicación efectiva se vuelve esencial para generar valor a largo plazo (Schmarzo, 2014). Los clientes satisfechos no solo permanecen fieles, sino que también se convierten en defensores de la marca, generando referencias y aumentando la reputación de la empresa en un ciclo de retroalimentación positiva que refuerza su posición en el mercado (Reichheld y Sasser, 1990). Esta relación estrecha con los clientes se basa en la innovación continua en la

gestión de datos, permitiendo una adaptación dinámica y proactiva a las necesidades cambiantes de los consumidores.

La innovación, respaldada por la infraestructura y las capacidades del *Big Data*, desencadena la generación de ideas disruptivas y estrategias efectivas (Constantiou y Kallinikos, 2015). La exploración constante de nuevas técnicas analíticas y el uso innovador de herramientas tecnológicas avanzadas permiten a las organizaciones basadas en datos descubrir oportunidades ocultas en los datos, identificar patrones significativos y establecer relaciones predictivas que influyen en la toma de decisiones proactivas y acertadas. Así mismo, estas organizaciones emplean su capacidad para analizar grandes volúmenes de información con el fin de identificar oportunidades emergentes en el mercado, lo que les permite crear ofertas innovadoras y ajustadas a la demanda del consumidor (Haskel y Westlake, 2017). Al respaldarse en datos precisos y análisis profundos, esta estrategia no solo impulsa el desarrollo de nuevos productos y servicios, sino que también puede desencadenar un aumento significativo en las ventas y la participación en el mercado.

Simultáneamente, la eficiencia en la gestión de recursos se vuelve fundamental para la generación de valor en las organizaciones basadas en datos. Utilizar inteligentemente los datos les permite optimizar procesos internos, reducir costos y potenciar la productividad. El análisis de datos revela áreas de mejora, identifica ineficiencias y proporciona *insights* para la toma de decisiones más efectivas, contribuyendo así a mejorar la eficiencia operativa y a recortar gastos innecesarios (Schmarzo, 2014).

El ecosistema del *Big Data*, combinado con la innovación, no solo simplifica la toma de decisiones informadas, sino que también estimula un ciclo de mejora y adaptación continuo. La innovación en la gestión de datos impulsa la optimización de procesos internos y el desarrollo de nuevos productos y servicios (Schmarzo, 2014). Este enfoque innovador propicia una evolución continua en las organizaciones, permitiéndoles no solo mantenerse vigentes, sino también prosperar en un entorno empresarial que cambia constantemente.

La clasificación de los tipos de datos se convierte en un soporte esencial en este contexto, ya que proporciona el marco necesario para comprender la naturaleza y la estructura de la información manejada. Según Bryman y Bell (2015), “la clasificación de los datos es

esencial para poder entender su naturaleza y determinar su importancia” (p.4). Los datos se pueden clasificar según diversas características como su rango, su origen o su estructura. Esta última es la más práctica y usada de forma global. Según esta, hay 3 tipos de datos: estructurados, semiestructurados y no estructurados.

Los datos estructurados son aquellos que se almacenan en bases de datos y se pueden analizar fácilmente mediante herramientas de análisis de datos. Los datos no estructurados son aquellos que no tienen una estructura definida y son difíciles de analizar. Los datos semiestructurados, por otro lado, son una combinación de datos estructurados y no estructurados y pueden incluir documentos, correos electrónicos y archivos XML (Shah, 2018).

La generación de valor en las organizaciones impulsadas por datos se ha convertido en un factor crucial para su éxito en un entorno empresarial altamente competitivo. En contraste con el modelo tradicional de producción basado en bienes primarios, el valor en las *Data Driven Organizations* se nutre principalmente de la capacidad para analizar y aprovechar los datos en todas sus formas, especialmente los no estructurados (Haskel y Westlake, 2017). A continuación se profundiza sobre este punto.

## **1.2. Datos no estructurados en las organizaciones**

En el tejido digital de la actualidad, las organizaciones se sumergen en un vasto océano de datos en constante flujo y provenientes de diversas fuentes heterogéneas. La mayoría abrumadora de los datos manejados pertenecen a la categoría no estructurada. Según una investigación realizada por IDC<sup>2</sup>, en 2019 se generaron aproximadamente 59 zettabytes (ZB) de datos, y se proyecta que esta cifra aumente a 175 ZB para 2025, con alrededor del 80% correspondiente a datos no estructurados (Gantz y Reinsel, 2020).

Los datos no estructurados abarcan imágenes, videos, correos electrónicos, publicaciones en redes sociales y más, careciendo de una organización y formato predefinidos. La multiplicidad de orígenes convierte a este tipo de datos en un panorama complejo y en constante evolución, desafiando a las organizaciones a abordarlos con creatividad y tecnología avanzada para extraer valor significativo (Lee, 2017).

---

<sup>2</sup> IDC significa *International Data Corporation*. Es la principal firma mundial de inteligencia de mercado, servicios de consultoría, y eventos para los mercados de Tecnologías de la Información, Telecomunicaciones y Tecnología de Consumo.

La incorporación de datos no estructurados representa un cambio paradigmático en la forma en que las organizaciones abordan la gestión y el análisis de la información. La magnitud y complejidad de estos datos requieren enfoques novedosos y tecnologías avanzadas para desentrañar su potencial. Los profesionales en este campo desempeñan un papel fundamental en esta transformación, aplicando sus habilidades y conocimientos para convertir datos no estructurados en ideas estratégicas que impulsen el crecimiento y la innovación en las organizaciones del siglo XXI (McAfee y Brynjolfsson, 2012).

Maniobrar y prosperar en medio del flujo constante de datos no estructurados implica un delicado equilibrio entre oportunidades y desafíos. Las organizaciones se encuentran ante el desafío de extraer conocimientos profundos y reveladores de este tipo de datos que son complejos de procesar. Pero también se deben enfrentar a obstáculos considerables para dar sentido a la información posible de extraer.

En la primera parte de esta sección, se abordan los desafíos intrínsecos de la incorporación de datos no estructurados en un contexto organizacional, que van desde la carencia de estandarización hasta las complicaciones en la realización de un procesamiento y análisis eficiente. Después, se analiza detalladamente las oportunidades latentes en los datos no estructurados. Se destacará cómo la combinación de la interpretación experta y el uso de tecnologías avanzadas pueden transformar la aparente anarquía en una mina de oro de información estratégica. La segunda sección aborda el rol esencial que desempeña la gestión en la creación de una estrategia de datos holística. A medida que las organizaciones se esfuerzan por tomar decisiones informadas y adaptativas, la habilidad de recolectar, almacenar y organizar datos no estructurados adquiere su propio protagonismo.

### **1.2.1. Desafíos y oportunidades de los datos no estructurados**

Explorar el vasto territorio de los datos no estructurados conlleva adentrarse en un mundo de desafíos intrínsecos que trascienden su aparente diversidad. Estos desafíos abarcan desde la carencia de estandarización, que dificulta la uniformidad en el análisis, hasta las complejidades del procesamiento y análisis eficiente debido a su volumen y complejidad. Sin embargo, detrás de estas dificultades, se esconde un espectro de oportunidades latentes que añaden profundidad y riqueza a la comprensión de estos datos (Katamesh *et al.*, 2021).

Los datos no estructurados albergan información detallada y contextual capaz de proporcionar una comprensión profunda y enriquecedora de diversos temas. Por ejemplo, con el análisis de texto, los matices de emociones humanas y las relaciones subyacentes emergen como elementos que pueden enriquecer considerablemente su interpretación. Además, estos datos pueden encerrar patrones y tendencias ocultas, cuya identificación resulta difícil con enfoques tradicionales (Chen *et al.*, 2014).

El uso de datos no estructurados en el contexto organizacional plantea desafíos significativos desde una perspectiva operativa. La diversidad de fuentes y formatos de estos datos dificulta su recopilación y almacenamiento eficiente. Por ejemplo, una organización que intenta analizar el sentimiento de los clientes sobre sus productos puede encontrarse con la tarea de reunir información dispersa en redes sociales, encuestas en línea y correos electrónicos de servicio al cliente, cada uno con su propio formato y estructura.

La complejidad en el procesamiento y análisis de datos no estructurados constituye un segundo obstáculo fundamental. Este tipo de datos requiere del uso de técnicas avanzadas para extraer información significativa. Un caso típico sería el de una empresa que desea analizar el contenido de las reseñas de productos en línea para identificar tendencias o problemas comunes. Aquí, el desafío radica en convertir el texto no estructurado en datos procesables que puedan alimentar modelos analíticos.

La integración de datos no estructurados con los sistemas existentes presenta una tercera dificultad. La interoperabilidad entre datos no estructurados y sistemas preexistentes de datos estructurados puede ser compleja y costosa. Por ejemplo, una empresa que busca mejorar la seguridad en sus instalaciones mediante la incorporación de datos de imágenes de cámaras de vigilancia puede enfrentar desafíos para integrar estos datos con su sistema de gestión de seguridad. Esta integración exitosa no solo requiere consideraciones técnicas, sino también la atención a preocupaciones de privacidad y seguridad.

El analizar la información no estructurada es un desafío, pero también puede convertirse en un aliado poderoso para desentrañar conexiones entre elementos que parecen inicialmente desconectados, y tomar decisiones más fundamentadas. La combinación de la interpretación experta y el uso de tecnologías avanzadas se revela como una fuerza transformadora en este escenario. A través del procesamiento de lenguaje natural (*NLP*),

las máquinas pueden comprender y analizar el lenguaje humano, permitiendo la extracción de sentimientos, identificación de entidades y clasificación temática en grandes volúmenes de texto (Kang *et al.*, 2020).

El procesamiento del lenguaje natural (NLP) es "un campo de la inteligencia artificial y la lingüística computacional que se ocupa de las interacciones entre las computadoras y los seres humanos a través del lenguaje natural" (Jurafsky y Martin, 2019, p. 3). Se enfoca en "permitir que las computadoras comprendan, interpreten y generen lenguaje humano de manera útil" (Manning *et al.*, 2008). Utiliza algoritmos y técnicas para analizar y comprender el texto escrito o hablado, abarcando tareas como el reconocimiento del habla, la comprensión del lenguaje, la generación de lenguaje y la traducción automática (Russell y Norvig, 2022).

En paralelo, la visión por computadora emerge como una herramienta que otorga capacidad interpretativa a imágenes y videos, identificando objetos y lugares con precisión. Esta es un campo interdisciplinario que involucra a la inteligencia artificial y la ciencia de la computación para permitir que las máquinas comprendan y analicen imágenes y videos digitales, imitando la capacidad humana de ver y procesar visualmente el entorno. Según Szeliski (2010), la visión por computadora abarca "el desarrollo de algoritmos y técnicas para la interpretación automática de información visual" (p. 3). Esta disciplina se ocupa de tareas como el reconocimiento de objetos, el seguimiento de movimientos, la reconstrucción tridimensional y la segmentación de imágenes. Autores como Forsyth y Ponce (2011) destacan la diversidad de aplicaciones de la visión por computadora, desde sistemas de vigilancia y medicina hasta la conducción autónoma y la realidad aumentada.

Por otro lado, el aprendizaje automático (*Machine Learning*) permite que los algoritmos analicen datos no estructurados y descubran patrones que podrían escapar a la percepción humana, especialmente en datos de texto, audio y video (Shinde, 2018). Este se enfoca en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender y mejorar automáticamente a partir de la experiencia y los datos, sin requerir una programación explícita para cada tarea. Según Mitchell (1997), el aprendizaje automático se define como "un programa de computadora se dice que aprende de la experiencia E con respecto a alguna tarea T y alguna medida de desempeño P, si su desempeño en T, medido por P, mejora con la experiencia E" (p. 2). El objetivo es que los sistemas

informáticos sean capaces de identificar patrones y tomar decisiones o realizar predicciones basadas en datos previos.

Autores como Hastie, Tibshirani y Friedman (2009) resaltan las categorías principales del aprendizaje automático, como el aprendizaje supervisado, no supervisado y por refuerzo. Mientras que en el aprendizaje supervisado los modelos se entrenan con conjuntos de datos etiquetados y el no supervisado identifica patrones sin etiquetas explícitas, la intersección entre visión por computadora y NLP se refleja en la capacidad de aplicar ambos enfoques. Por ejemplo, en el aprendizaje supervisado de la visión por computadora, se pueden utilizar imágenes etiquetadas para entrenar modelos en la detección de objetos, mientras que en NLP, el análisis de texto con etiquetas puede permitir el reconocimiento de entidades o la clasificación de temas. En el aprendizaje no supervisado, la visión por computadora puede agrupar imágenes sin etiquetas en categorías basadas en características compartidas, similar al NLP que puede realizar agrupamientos de textos no etiquetados en función de similitudes semánticas.

En cuanto al aprendizaje por refuerzo, tanto la visión por computadora como el NLP pueden emplearse en la interacción con el entorno, por ejemplo, el reconocimiento de patrones en imágenes o la interpretación de interacciones verbales en aplicaciones de asistencia virtual. En medio de esta interacción entre desafíos y oportunidades, la gestión de datos no estructurados resulta necesaria. A medida que la información fluye en formas diversas y aparentemente caóticas, la necesidad de una estrategia integral para su manejo se vuelve ineludible. La implementación de sistemas que permitan el almacenamiento, organización y acceso eficiente a estos datos adquiere un significado fundamental en este contexto. La gestión adecuada no solo disminuye los obstáculos operativos inherentes a la diversidad de formatos, sino que también facilita la extracción de valor y conocimiento desde los datos no estructurados.

### **1.2.2. El rol de la gestión de datos no estructurados**

La gestión de datos no estructurados se convierte en un pilar esencial en la construcción de una estrategia de datos holística. Esta estrategia abarca un enfoque integral para la gestión, análisis y utilización de todos los tipos de datos disponibles, incluyendo los no estructurados como ser textos, imágenes, audios y videos. Una estrategia de datos holística implica no solo la recopilación y almacenamiento eficiente de estos datos diversos, sino también la implementación de herramientas y técnicas avanzadas de

análisis, como el procesamiento del lenguaje natural, el reconocimiento de patrones y la visión por computadora. Esto permite no solo comprender y aprovechar la información contenida en datos no estructurados, sino también integrarla con datos estructurados para obtener una visión completa y precisa.

Si bien los desafíos para las organizaciones son notables, la gestión adecuada de datos actúa como un puente que conecta los aspectos técnicos y estratégicos (Couto, 2017). Al establecer procesos sólidos para la adquisición, almacenamiento y análisis de estos datos, las organizaciones pueden transformar la complejidad en simplicidad, convirtiendo los desafíos en oportunidades. Con una gestión adecuada se optimiza la capacidad de almacenamiento y análisis, influyendo en estrategias globales en un mundo en constante evolución, donde la información impulsa el progreso (Aja, 2002).

Enriquecer la fuente de datos es esencial al incorporar datos no estructurados en la estrategia, permitiendo la adquisición de información detallada, contextos y matices enriquecedores. La mejora en la toma de decisiones surge de la gestión efectiva de estos datos, desvelando patrones y relaciones ocultas en contextos cambiantes.

La gestión efectiva de datos comienza con una etapa crucial de recopilación, transformación y almacenamiento de información (Aja, 2002). En esta fase inicial, es fundamental establecer un marco robusto que permita la captura de datos desde diversas fuentes, como sensores, dispositivos, sistemas de gestión organizacional, redes sociales y otros canales relevantes para la organización. Esta recopilación debe realizarse de manera estructurada, garantizando la integridad y la calidad de los datos desde su origen.

Una vez recopilados, los datos necesitan ser transformados y preparados para su almacenamiento y análisis. Esta transformación puede incluir la limpieza de datos para eliminar errores, valores atípicos o datos duplicados, así como la normalización y estandarización para asegurar la coherencia en la estructura y el formato (Couto, 2017). Además, es importante enriquecer los datos con metadatos descriptivos que faciliten su comprensión y uso posterior. Esta etapa de transformación es fundamental para garantizar que los datos sean útiles y confiables para la toma de decisiones.

El almacenamiento de datos debe ser gestionado de manera eficiente, aprovechando tecnologías innovadoras de gestión de bases de datos y sistemas de almacenamiento escalables. Es importante seleccionar la infraestructura adecuada que pueda manejar el

volumen y la variedad de datos de manera efectiva, ya sea mediante soluciones de almacenamiento en la nube, bases de datos distribuidas o sistemas de almacenamiento en memoria (Shinde, 2018). Se deben implementar políticas de seguridad y protección de datos para garantizar la confidencialidad y la integridad de la información almacenada, cumpliendo con las regulaciones y estándares de privacidad aplicables. Además, la utilización de herramientas de análisis de datos avanzadas, como técnicas de minería de datos, inteligencia artificial y aprendizaje automático, permite extraer conocimientos significativos de los datos, revelando patrones y tendencias relevantes en entornos en constante cambio.

La integración de datos no estructurados, en conjunto con datos estructurados, en las estrategias de gestión de datos es esencial para enriquecer la fuente de información, proporcionando una visión más completa y detallada de los contextos organizacionales. Este enfoque holístico permite mejorar la toma de decisiones al identificar relaciones ocultas y comprender mejor los matices del mercado, facilitando la adaptación ágil a las demandas cambiantes y promoviendo estrategias empresariales más efectivas y orientadas hacia el progreso, en línea con las afirmaciones de Aja (2002).

La agilidad organizacional se logra al integrar señales tempranas de cambios en la estrategia adaptativa, facilitando una respuesta más rápida y precisa (Calderón *et al.*, 2017). Identificar oportunidades emergentes, personalizar experiencias del cliente y fomentar la investigación y el desarrollo constituyen ventajas notables. La captura, análisis y utilización de datos no estructurados confieren a las organizaciones una ventaja competitiva sustancial.

En la actualidad, muchas organizaciones están aprovechando estas herramientas tecnológicas en diversas áreas de su operación, siendo un ejemplo concreto su implementación en estrategias de *Marketing* y toma de decisiones (Lalaleo *et al.*, 2023). Aquellas que se enfocan en el *Marketing* organizacional basado en datos cosechan considerables beneficios al poder recolectar, analizar y aplicar datos no estructurados para una mejor comprensión de sus clientes y optimizar sus campañas publicitarias.

### **1.3. *Marketing* organizacional basado en datos estructurados y no estructurados**

Según Kotler y Armstrong (2016), el *Marketing* se define como "el proceso social y administrativo por el cual los grupos e individuos obtienen lo que necesitan y desean a

través de la creación, oferta e intercambio de productos de valor con otros" (p. 32). Desde sus orígenes, el *Marketing* ha evolucionado constantemente para adaptarse a las cambiantes dinámicas del mercado y las preferencias del consumidor (Armstrong y Kotler, 2003). Sin embargo, en la era actual, una nueva dimensión ha transformado la forma en que se concibe y se ejecuta el *Marketing*: los datos.

El enfoque tradicional del *Marketing* se basaba en estrategias de segmentación y posicionamiento, y estaba impulsado por la experiencia (Vidal, 2016). Sin embargo, con el advenimiento de la tecnología digital y la capacidad de recopilar y analizar datos a gran escala, ha surgido una nueva forma de hacer *Marketing*: el *Data-Driving Marketing*. Este enfoque pone en relevancia el poder de los datos para informar, guiar y optimizar las decisiones de *Marketing* en todas las etapas del proceso de toma de decisiones (Jeffery, 2010). A diferencia de las suposiciones basadas en la intuición, el *Data-Driving Marketing* se basa en la evidencia respaldada por datos concretos.

En este contexto, los datos se convierten en la brújula que orienta las estrategias de *Marketing* (Armstrong y Kotler, 2003). Desde la identificación de la audiencia adecuada hasta la personalización de mensajes y la evaluación de la visibilidad de la marca, los datos desempeñan un papel fundamental. Permite detectar patrones de comportamiento del consumidor, preferencias y reacciones a campañas anteriores, permitiéndole a las empresas tomar decisiones más informadas y estratégicas.

Al hacer una revisión en la evolución del *Marketing*, se resaltan los conceptos de Michael Porter sobre la estrategia competitiva y la diferenciación. Porter (1990), enfatizó la importancia de identificar y explotar las ventajas competitivas únicas para destacar en el mercado. Sus contribuciones recalcan la necesidad de comprender el entorno competitivo en el que operan las empresas, así como la relevancia de la diferenciación estratégica para establecer una posición sólida en el mercado. Porter (1990) argumenta que la clave para el éxito empresarial radica en la habilidad de una empresa para ofrecer valor único a sus clientes, ya sea a través de la eficiencia en costos o de la creación de productos y servicios distintivos. Esta perspectiva influyó significativamente en el campo del *Marketing* al subrayar la importancia de la estrategia a largo plazo y el análisis exhaustivo de los factores competitivos, elementos esenciales para el desarrollo de estrategias efectivas y sostenibles en un mercado dinámico y competitivo.

Si bien estos principios siguen siendo relevantes, el *Data-Driving Marketing* incorpora la precisión y efectividad. Este permite a las empresas optimizar sus estrategias en función de datos en tiempo real. En lugar de confiar únicamente en la diferenciación estática, las empresas pueden adaptarse dinámicamente a las tendencias cambiantes y a las necesidades individuales del cliente (Jeffery, 2010). Esto no solo mejora la eficacia de las campañas, sino que también fortalece la relación con los clientes al demostrar un entendimiento profundo de sus preferencias.

Si bien el *Marketing* televisivo ha sido un pilar en la promoción de productos y servicios a través de programas y anuncios, lo frecuentemente destacado del *Data-Driving Marketing* es el *Product Placement*. Se refiere al tiempo y contexto en que se muestra un producto en pantalla jugando un papel crucial en el impacto de la estrategia. Por esta razón su medición se considera clave. A su vez, las decisiones sobre qué productos colocar y cómo hacerlo requieren mayor precisión. En la siguiente sección, se explora cómo el enfoque basado en datos ha revolucionado el *Product Placement* y cómo las marcas pueden aprovechar esta estrategia de manera más efectiva en el mundo televisivo.

### **1.3.1. *Product Placement***

La revolución del enfoque del *Data-Driving Marketing* ha dejado una marca profunda en el ámbito del *Product Placement*, especialmente en el mundo televisivo. Este enfoque ha transformado la forma en que las marcas se relacionan con su audiencia y han redefinido la efectividad de esta estrategia tradicional (Morgado, 2007). Al aprovechar los datos para informar sus decisiones, las marcas pueden maximizar su impacto y crear conexiones más auténticas con el público.

El *Product Placement*, que implica incorporar discretamente productos o marcas dentro de programas de televisión o películas, solía ser una estrategia basada en suposiciones (Baños y Rodríguez, 2012). Las marcas seleccionaban ubicaciones basándose en la intuición y la visión creativa, sin datos concretos que respaldaran sus decisiones. Sin embargo, con el surgimiento del *Marketing* basado en datos, esta estrategia ha experimentado una metamorfosis.

En la actualidad, las marcas pueden recopilar y analizar datos demográficos, psicográficos y de comportamiento de la audiencia para identificar las ubicaciones de *Product Placement* más efectivas (Rodríguez, 2016). Los datos permiten a las marcas seleccionar

productos que resuenen con los intereses y preferencias de la audiencia, aumentando la autenticidad y la relevancia de la estrategia. Además, la capacidad de rastrear la exposición del *Product Placement* en tiempo real proporciona información valiosa sobre la efectividad de la estrategia y permite realizar ajustes sobre la marcha (Morgado, 2007).

Para aprovechar esta estrategia de manera más efectiva en el mundo televisivo, las marcas deben adoptar un enfoque basado en datos desde el inicio. Esto implica analizar en profundidad la audiencia del programa y comprender sus características y comportamientos clave (Rodríguez, 2016). Al utilizar herramientas de análisis de datos, las marcas pueden identificar patrones de consumo, preferencias y tendencias que guiarán sus decisiones de *Product Placement*.

Además, resulta necesario que las marcas elaboren métricas claras y objetivos medibles para evaluar el éxito de la estrategia (Jeffery, 2010). Las métricas pueden incluir la visibilidad del producto, el tiempo de exposición, la resonancia con la audiencia y el aumento en el reconocimiento de la marca. Estos datos cuantificables permiten una evaluación informada del impacto y la rentabilidad del *Product Placement*.

### **1.3.2. Importancia de Medir la Exposición del *Product Placement***

La importancia de medir la exposición del *Product Placement* en el ámbito del *Marketing* televisivo radica en su capacidad para proporcionar una visión precisa y cuantificable del impacto de esta estrategia (Torrano y Flores, 2007). Los datos obtenidos de un anuncio no solo revelan la presencia del producto en la pantalla, sino que también proporcionan información sobre la percepción y la interacción de la audiencia con dicho *placement*. Esta información es crucial para las marcas, ya que les permite comprender cómo su presencia en el contexto televisivo es percibida, recibida y recordada por la audiencia.

Sin embargo, estos datos no se limitan a métricas cuantitativas; también incorporan datos cualitativos derivados de la interpretación subjetiva de la integración del producto en la trama del programa y las emociones suscitadas en la audiencia, lo que brinda una comprensión más profunda y rica de la efectividad del *Product Placement*. La esencia de medir la exposición del *Product Placement* radica en su capacidad para ofrecer una perspectiva detallada y multidimensional del impacto de esta estrategia en el mercado televisivo.

En el contexto de medir la exposición del *Product Placement*, el enfoque se centra en transformar los datos no estructurados en datos estructurados específicamente relacionados con la exposición del producto en pantalla. Este proceso implica la aplicación de técnicas de procesamiento de datos para identificar y cuantificar la presencia del producto o marca en el contenido televisivo. Por ejemplo, mediante el análisis de imágenes o videos, se pueden detectar y registrar cada instancia en la que el producto aparece en la pantalla, así como la duración y el contexto de dicha exposición. Una vez que los datos no estructurados se han transformado en datos estructurados de exposición del *Product Placement*, se pueden utilizar para construir métricas específicas que brinden información valiosa sobre la efectividad de la estrategia de *Marketing*.

La medición de la exposición brinda a las marcas una idea clara de cuánto tiempo sus productos o marcas han estado visibles en la pantalla y en qué contextos específicos (Velarde y Lau, 2010). Esto va más allá de la mera presencia visual, ya que permite evaluar la calidad y el grado de integración del *Product Placement* en la trama del programa. Por ejemplo, se puede medir si la exposición fue incidental o si realmente aportó valor a la historia contada. Los datos recopilados ofrecen una evaluación detallada de la efectividad de la estrategia.

Los datos recopilados sobre la exposición también ofrecen información valiosa sobre la percepción de la audiencia hacia el *Product Placement*. Las reacciones emocionales, la resonancia con los espectadores y los niveles de recuerdo son aspectos que se pueden medir y analizar. Esto permite a las marcas comprender cómo la audiencia está interactuando con sus productos o marcas dentro del contexto del programa y si están generando una respuesta positiva o negativa (Barro *et al.*, 2016).

Uno de los mayores beneficios de la medición de la exposición es su capacidad para informar estrategias futuras y ajustar enfoques. Al analizar los datos recopilados, las marcas pueden identificar qué aspectos de la estrategia funcionaron bien y cuáles podrían necesitar mejoras (Baños y Rodríguez, 2012). Esta retroalimentación permite refinar las decisiones en términos de selección de ubicaciones, productos o marcas a destacar, y la forma en que se integran en la narrativa. A medida que se recopilan y analizan más datos a lo largo del tiempo, las marcas pueden iterar y mejorar continuamente su enfoque de *Product Placement*.

La medición de la exposición también desempeña un papel esencial en la maximización de la visibilidad de la marca. Los datos permiten a las marcas evaluar el impacto real de su inversión en *Product Placement* en relación con los objetivos establecidos. Esto puede incluir objetivos como el aumento del reconocimiento de la marca, la mejora de la percepción del producto o el impulso de las ventas. Al comprender cómo los datos de exposición se traducen en resultados tangibles, las marcas pueden tomar decisiones más informadas sobre cómo asignar recursos y ajustar su estrategia para lograr optimizar la visibilidad de la marca y a su vez la inversión.

## **Conclusiones**

En el presente capítulo, se ha expuesto la importancia del *Big Data* en la gestión organizacional, evidenciando su influencia directa en la toma de decisiones estratégicas, la optimización de procesos internos y la búsqueda de ventajas competitivas en el mercado. Esta herramienta emerge como un recurso fundamental que permite a las organizaciones aprovechar al máximo el vasto conjunto de datos disponibles para mejorar su rendimiento y posicionamiento en el ámbito organizacional. Se evidencia una transformación significativa en las organizaciones contemporáneas, evolucionando hacia entidades basadas en datos, donde la capacidad para gestionar y analizar grandes volúmenes de información se convierte en un activo estratégico fundamental.

También se abordó el hecho de que las organizaciones basadas en datos se encuentran en la constante tarea de aprovechar todo el espectro de información disponible. Sin embargo, dado que la mayoría de estos datos son no estructurados, se presenta un desafío adicional. Estos abarcan una amplia gama de fuentes y formatos, desde correos electrónicos hasta publicaciones en redes sociales, lo que requiere un enfoque meticuloso para su estudio y análisis. Es esencial para estas organizaciones implementar estrategias sólidas de gestión de datos que les permitan extraer conocimientos valiosos y tomar decisiones informadas a partir de este recurso aparentemente caótico.

En dicho contexto, se hizo hincapié en la importancia del análisis de datos no estructurados en la formulación de estrategias de *Marketing* personalizadas, resaltando su capacidad para descubrir patrones y preferencias que proporcionan una ventaja competitiva a las organizaciones al adaptar sus acciones de manera más precisa a las necesidades del mercado. Este enfoque en datos no estructurados resalta tanto los desafíos

como las oportunidades que presentan para las organizaciones. La gestión efectiva de estos datos se convierte así en un elemento crucial para aprovechar su potencial y obtener conocimientos valiosos que impulsen la competitividad y la eficiencia operativa de la organización.

La orientación hacia estrategias basadas en datos en el *Marketing* se refleja en prácticas concretas como el *Product Placement*. Este método demanda una meticulosa medición para comprender su verdadero impacto en el público objetivo. La precisión en la medición de la exposición del *Product Placement* se convierte en un elemento esencial para evaluar su efectividad real y así perfeccionar su integración dentro de las estrategias de *Marketing*. Esta focalización en la recolección de datos precisos y relevantes se presenta como un paso crucial en la optimización del impacto y la eficacia del *Product Placement* como herramienta estratégica en el ámbito del *Marketing*.

El desafío crucial reside en la gestión y análisis efectivo de datos no estructurados en el ámbito del *Marketing*. Esta tarea implica enfrentar aspectos complejos, incluyendo la recolección meticulosa de datos mediante el uso de modelos de detección avanzados, como las Redes Neuronales. Estos modelos tienen como objetivo extraer información relevante y específica relacionada con el *Product Placement*, permitiendo así una comprensión más profunda y precisa de su impacto y alcance en el mercado. Dicha temática será abordada en el capítulo 2 a continuación.

## **Capítulo 2: Datos no estructurados en el *Product Placement*, recolección e información proporcionada**

### **Introducción**

La inserción de productos, conocida como *Product Placement*, se ha convertido en una táctica de *Marketing* de gran relevancia y cada vez más integrada en la industria del entretenimiento (Morgado, 2007). La efectividad de esta estrategia radica en gran medida en la capacidad de evaluar y comprender el posicionamiento de los productos dentro de contextos visuales (Baños y Rodríguez, 2012). Este enfoque publicitario ha cobrado gran importancia debido a su capacidad para colocar los productos de manera estratégica en escenarios de programas, películas o contenido digital (Torrano y Flores, 2007).

La relevancia y la integración efectiva de los productos en el entorno visual tienen un impacto directo en cómo percibe el espectador la estrategia de *Marketing* (Morgado,

2007). No basta con solo detectar la presencia del producto; es igualmente importante entender cómo se fusiona de forma natural en la escena. La comprensión de elementos como los colores más visibles, el tamaño, la ubicación precisa y la integración dentro del contexto resulta esencial (Rumpf *et al.*, 2019). Por lo tanto, evaluar y comprender adecuadamente esta presencia visual es crítico para determinar la efectividad del *Product Placement*.

En este contexto, surge la siguiente pregunta: ¿Cómo influye la recopilación, análisis y procesamiento de datos no estructurados utilizados en modelos de detección para la generación de información relevante en el diseño de estrategias de *Product Placement* en organizaciones? Para responder este interrogante, en el presente capítulo, se aborda la recolección y medición de los datos no estructurados provenientes del *Product Placement* para comprender su impacto y eficacia.

Con el propósito de profundizar en la influencia del análisis de datos no estructurados en la recopilación de información relevante, este capítulo se organiza en tres secciones. En la primera sección, se analizan los datos preliminares derivados del *Product Placement*, abordando elementos fundamentales como los *frames*, píxeles y colores presentes en el contexto visual de las escenas. Aunque puedan parecer elementos simples, desempeñan un papel central para comprender la presencia y la representación de productos en los entornos mediáticos.

Posteriormente, en una segunda sección, se emplea una metodología para recolectar estos datos, donde los modelos de detección, particularmente las Redes Neuronales, desempeñan un papel vital. Estos modelos, debido a su capacidad para analizar imágenes de manera compleja, son esenciales para la identificación y extracción de información valiosa sobre la presencia de productos en escenarios audiovisuales (Olabe, 1998).

Finalmente, en la tercera sección se profundiza en la información obtenida a través de estos modelos de detección, analizando cómo los datos no estructurados se convierten en métricas y detalles esenciales para evaluar la efectividad del *Product Placement* en el contexto mediático actual.

## **2.1. Datos preliminares del *Product Placement***

El *Product Placement* se caracteriza por poseer una gran cantidad de información no estructurada, ya que no se encuentra organizada ni tiene un formato específico. Esta información no estructurada abarca diferentes aspectos del *Product Placement*. Por un lado, se encuentran los diálogos o menciones verbales, que son textos o transcripciones de conversaciones que hacen referencia a productos específicos (Russell, 2002). Estas menciones pueden formar parte del guion, surgir de diálogos improvisados o ser comentarios espontáneos. Por otro lado, están los sentimientos y percepciones, que son las opiniones, reacciones o emociones expresadas por los personajes o el público en relación con la colocación de productos. Estos comentarios pueden ser positivos, negativos o neutrales y proporcionan información valiosa sobre la marca o el producto.

Además, uno de los elementos fundamentales del *Product Placement* son las descripciones visuales. Estas se definen como imágenes o fotogramas que muestran productos integrados en escenas de medios. El presente trabajo, se centra específicamente en las descripciones visuales, utilizando un video<sup>3</sup> de acceso público de la marca PedidosYa<sup>4</sup>. Su elección se debe a que es una marca conocida, fácil de recordar y además invierte en la colocación de productos, concretamente en *realities* como Máster Chef o en ligas de fútbol.

Figura 1: Imagen de video de la marca PedidosYa



Fuente: imagen tomada de *YouTube*, del canal de PedidosYa

La Figura 1 muestra una imagen de video que es un dato no estructurado de la marca PedidosYa. Este video es de carácter público y se encuentra en *YouTube*, y constituye un ejemplo de cómo el *Product Placement* puede ser utilizado para integrar un producto en

---

<sup>3</sup> Disponible en <https://www.youtube.com/watch?v=CNiAAbfkNzY>

<sup>4</sup> El video se centra en PedidosYa Market

el contexto visual de una producción televisiva, en este caso la aparición de la bolsa con el nombre la marca.

En las secciones siguientes se adentrará en un análisis más detallado de los elementos fundamentales en el estudio del *Product Placement* en televisión: *frames*, píxeles y colores. Estos componentes proveen información esencial para evaluar la exposición de un producto en una producción televisiva. Se explora cómo la descomposición de *frames* en imágenes estáticas, el análisis de píxeles y la interpretación de colores se combinan para brindar una comprensión más profunda de cómo los productos interactúan con el contenido visual. Estos datos preliminares no solo revelan la presencia del producto, sino que también destacan la forma en que se integra en el contexto visual, permitiendo una evaluación más completa de su impacto en la audiencia y en las estrategias de *Marketing* futuras.

### **2.1.1. *Frames***

Los videos son una secuencia de imágenes o *frames* que se reproducen de forma secuencial a una determinada velocidad. Cada *frame* es una imagen fija que captura un instante en el tiempo, y al reproducirse en rápida sucesión, crea la ilusión de movimiento (Meyer *et al.*, 2011). En el contexto del *Product Placement*, la información visual no estructurada se puede obtener a partir de los *frames* de un video. Cada *frame* puede mostrar productos integrados en escenas, permitiendo analizar cómo se presentan los productos, quién los utiliza, el contexto en el que se encuentran, entre otros detalles relevantes.

Como se mencionó previamente, para este trabajo se toma un video de acceso público de la marca PedidosYa. El video utilizado tiene una duración de 30 segundos, y contiene 25 *frames* por segundo. Por lo tanto, en total, el video está compuesto por 750 *frames*. En la Figura 2 a continuación se muestran 4 de los 750 *frames* que forman parte del video.

Figura 2: *Frames* del video de la marca PedidosYa



Fuente: Elaboración propia con Python


Cada uno de estos *frames* se considera como el id, siendo representado en las filas del conjunto de datos a utilizar. A su vez, cada *frame* está compuesto por una cuadrícula de píxeles dispuestos en filas y columnas. Un píxel es la unidad más pequeña de información visual en una imagen digital. La palabra "píxel" proviene de la contracción de "elemento de imagen" en inglés (*picture element*). En este caso el video tiene un tamaño de 1280 x 720 píxeles. A continuación, se detalla sobre estos.

### 2.1.2. Píxeles

Cada píxel representa un punto en una cuadrícula bidimensional y contiene información sobre el color y la intensidad de la luz en ese punto específico de la imagen. Los píxeles son los bloques básicos que componen una imagen digital. Al unir una cantidad significativa de píxeles, se crea una representación visual más compleja y detallada (Blinn, 2005). En una pantalla o monitor, cada píxel corresponde a un punto de luz que se puede encender o apagar para formar la imagen completa.

La resolución de una imagen se mide en píxeles y se expresa en términos de la cantidad de píxeles que tiene en ancho y alto. Por ejemplo, una imagen de 1920x1080 píxeles tiene 1920 píxeles en su ancho y 1080 píxeles en su altura. Los píxeles también juegan un papel fundamental en la visualización y manipulación de imágenes digitales. Dado que cada píxel tiene un valor de color y brillo, se pueden realizar ajustes y ediciones en cada píxel individualmente para lograr efectos específicos en una imagen.

Figura 3: Píxeles del video de la marca PedidosYa



Fuente: Elaboración propia con Python

En la Figura 3 se muestra un *frame* y después se evidencia como es el *frame* sin las franjas negras. Esto permite observar cómo es el valor de uno de los píxeles, en este caso, marcado con el círculo rojo, concretamente es un píxel que está en la posición 174,100 en el eje *x* e *y* respectivamente y tiene los colores 87,80 y 51 en la escala RGB.

### 2.1.3. Colores

La forma en que funcionan los colores y la luz en relación con los píxeles se basa en el modelo de color RGB (*Red, Green and Blue*) y el sistema de visualización de las imágenes digitales (Somaraj, 2016). En el modelo de color RGB, los colores se generan combinando diferentes intensidades de luz de los tres colores primarios de la luz: rojo, verde y azul. Cada píxel de una imagen digital tiene subpíxeles individuales que emiten o reflejan luz en estas tres componentes de color.

En una pantalla, cada píxel contiene tres subpíxeles: uno para el rojo, otro para el verde y otro para el azul. Al variar la intensidad de luz de cada subpíxel, se crea una mezcla de colores que produce el color final percibido en ese píxel. La combinación de los tres colores primarios en diferentes proporciones permite generar una amplia gama de colores y tonalidades. Cuando se visualiza una imagen en una pantalla, la luz emitida o reflejada por los subpíxeles en cada píxel se combina para crear la imagen completa. A medida que

los píxeles individuales se muestran en rápida sucesión, el ojo humano percibe una imagen continua y en movimiento (Blinn, 2005).

Por otro lado, un *frame* en blanco y negro, también conocido como escala de grises, se compone de píxeles que solo tienen información de intensidad luminosa, sin información de color. En este caso, la intensidad de cada píxel se representa en una escala de grises que va desde el negro hasta el blanco, pasando por diferentes tonalidades de gris. El valor de intensidad de cada píxel determina qué tan claro u oscuro aparece en el *frame*. Por lo tanto, al clasificar un *frame*, se puede indicar si es un *frame* en color, identificando los componentes de color rojo, verde y azul, o si es un *frame* en blanco y negro, basado únicamente en la intensidad luminosa de cada píxel.

Figura 4: Colores en un *frame* del video la marca PedidosYa



Fuente: Elaboración propia con Python

En la Figura 4, se presenta un *frame* que exhibe los 4 colores posibles. Cada *frame* se compone de una matriz de 921.600 píxeles, distribuidos en 720 píxeles por fila y 1280 píxeles por columna. Cada píxel contiene información sobre tres colores distintos y una tonalidad de luz. Con el propósito de calcular la media, mediana y moda de estos valores, para usararlo en el modelo se ha optado por eliminar los bordes negros, lo que implica restar 153.600 píxeles por fila. Posteriormente, se lleva a cabo un bucle iterativo (*for*) para procesar cada uno de los píxeles y sus respectivos colores, realizando este procedimiento en cada uno de los *frames* correspondientes.

La información sobre *frames*, píxeles y colores está intrínsecamente vinculada a todos los vídeos, no requiere procedimientos adicionales y constituye la base para entender cómo se integran los productos en el contenido visual. Sin embargo, para detectar marcas en vídeos, se vuelve crucial el empleo de herramientas de inteligencia artificial. Estas

herramientas posibilitan la identificación y el reconocimiento de marcas específicas presentes en el material visual, donde los modelos de detección juegan un papel esencial.

Para poder iniciar un análisis del *Product Placement* se comienza con la recopilación de datos, la cual puede llevarse a cabo a través de modelos de detección. Estos modelos, fundamentados en la inteligencia artificial, son capaces de identificar la presencia de marcas en vídeos. Su funcionamiento radica en analizar los *frames*, píxeles y colores de los vídeos en busca de patrones visuales característicos que indiquen la presencia de una marca en particular. Es a través de esta exploración minuciosa que se logra comprender cómo los productos interactúan dentro del contexto visual de la producción televisiva.

## **2.2. Metodología para la recolección de datos del *Product Placement*: Modelos de detección**

Los modelos de detección son sistemas que identifican patrones o elementos específicos dentro de datos, imágenes o señales, permitiendo reconocer objetos, anomalías o eventos en entornos particulares (Smith, 2018). Estos modelos utilizan algoritmos y técnicas de análisis de datos para clasificar información, como la detección de objetos en imágenes.

La detección de características, como puntos clave en imágenes, y la identificación de anomalías, como patrones inusuales en datos, son aplicaciones comunes de estos modelos (Brown y Johnson, 2020). Los modelos de detección, en esencia, se centran en la extracción y análisis de información visual para reconocer elementos específicos en una imagen o vídeo. Para lograr predicciones precisas y confiables, es esencial contar con una o varias imágenes representativas del elemento que se busca identificar.

Las imágenes representativas se utilizan durante la fase de entrenamiento del modelo, donde se ajustan los parámetros para que el modelo aprenda y pueda reconocer adecuadamente los patrones asociados con el elemento específico en cuestión. Así, disponer de imágenes relevantes y representativas es crucial para el éxito y la eficacia de los modelos de detección en la identificación de elementos visuales en distintos contextos.

Figura 5: Logos de la marca PedidosYa



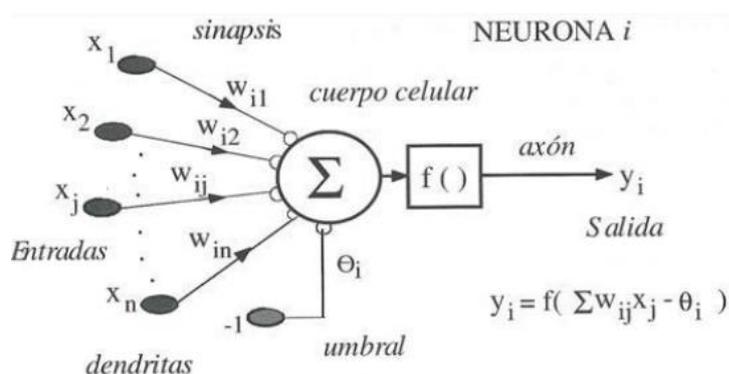
Fuente: Imágenes obtenidas en Google de la marca

En la Figura 5, se visualizan los logos de la Marca PedidosYa. Estos están presentes en la comunicación de sus productos por parte de la marca y suelen aparecer en comerciales. Con el fin de poder identificarlos se entrenarán modelos de redes neuronales ya que permiten reconocer este tipo de imágenes. Para abordar la identificación y reconocimiento de los logos de la Marca PedidosYa, se empleará una estrategia centrada en la utilización de Redes Neuronales como modelos de detección.

### 2.2.1. Redes Neuronales como modelos de detección

Las redes neuronales son modelos computacionales que imitan el funcionamiento del cerebro humano al procesar información. La unidad básica de una red neuronal es la neurona. Su estructura consta de capas de nodos interconectados que procesan datos de entrada y los transforman en salidas específicas (Díaz-Ramírez, 2021).

Figura 6: Modelo para neurona artificial

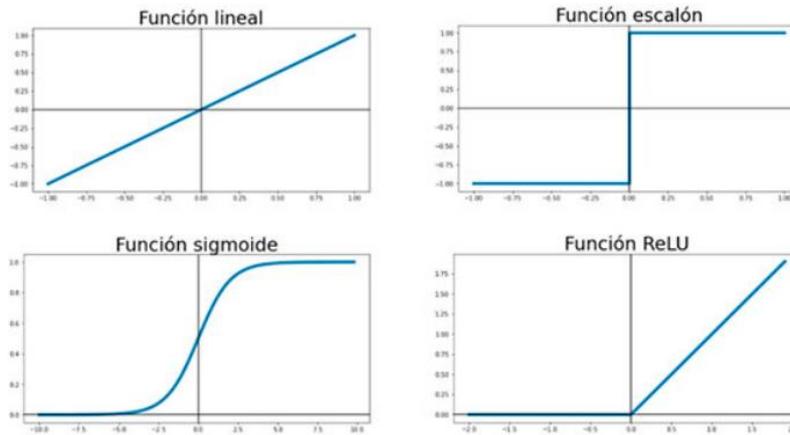


Fuente: Imagen obtenida de *Las redes neuronales: de la biología a los algoritmos de clasificaciones*, por Andrés Nacelle, 2009, Universidad de la República.

En la Figura 6 se muestra como cada neurona recibe múltiples entradas, cada una multiplicada por un peso sináptico  $w_{ij}$  asociado. La suma ponderada de todas estas entradas y pesos se calcula para una neurona específica. Matemáticamente, esto se representa como  $\sum_{j=1}^n w_{ij}x_j$  donde  $n$  es el número de entradas,  $w_{ij}$  es el peso de la

conexión entre la entrada  $x_j$  y la neurona  $i$ . Posteriormente se agrega un término de sesgo  $-\theta_i$  al resultado de la suma ponderada. El sesgo actúa como un umbral para la activación de la neurona. El potencial postsináptico total de la neurona  $i$  se obtiene mediante la fórmula  $z_i = \sum_{j=1}^n w_{ij}x_j - \theta_i$  (Nielsen, 2015).

Figura 7: Ejemplos de funciones de activación en redes neuronales



Fuente: Imagen obtenida de Sistema de detección y clasificación de obstáculos para JetBot basado en redes neuronales, por Alejandro Barrionuevo, 2021, Universidad de Sevilla.

La Figura 7 muestra algunas de las funciones de activaciones utilizadas en las redes Neuronales. La función de activación  $f()$  se aplica al potencial postsináptico. Esta función introduce no linealidades en la red y determina si la neurona se activa o no. La salida de la neurona  $y_i(t)$  se calcula como  $f(\sum_{j=1}^n w_{ij}x_j - \theta_i)$ .

Es importante destacar la importancia de la función de activación, ya que determina cómo se aplican los pesos para generar los resultados. Si se considera una función de activación lineal, la red neuronal funcionaría como una regresión lineal, donde los pesos son los coeficientes de las variables (Goodfellow, 2016). La regresión lineal es una técnica estadística utilizada para modelar la relación entre una variable dependiente ( $Y$ ) y una o más variables independientes ( $X$ ). Se asume que esta relación es lineal, es decir, que los cambios en las variables independientes están asociados con cambios constantes en la variable dependiente (Montgomery, 2021).

La forma más común de regresión lineal es la regresión lineal simple cuya ecuación es:

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (1)$$

donde  $Y$  es la variable dependiente (la variable a predecir),  $X$  es la variable independiente (la variable utilizada para predecir  $Y$ ),  $\beta_0$  es el término de intersección (el valor de  $Y$  cuando  $X$  es 0),  $\beta_1$  es el coeficiente de regresión (representa el cambio en  $Y$  por cada unidad de cambio en  $X$ ) y  $\varepsilon$  es el término de error (representa la diferencia entre el valor observado de  $Y$  y el valor predicho de  $Y$ ).

El objetivo en la regresión lineal es encontrar los valores de  $\beta_0$  y  $\beta_1$  que minimizan la suma de los cuadrados de los residuos, es decir, la diferencia entre los valores observados y los valores predichos. Esto se conoce como el método de mínimos cuadrados (Montgomery, 2021). Este método consiste en minimizar la suma de los cuadrados de los errores. Para el caso de la regresión lineal múltiple, donde hay más de una variable independiente, la ecuación (1) se generaliza a:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (2)$$

donde  $X_1, X_2, \dots, X_n$  son las variables independientes adicionales,  $\beta_0, \beta_1, \beta_2, \dots, \beta_n$  son los coeficientes de regresión correspondientes (Montgomery, 2021)

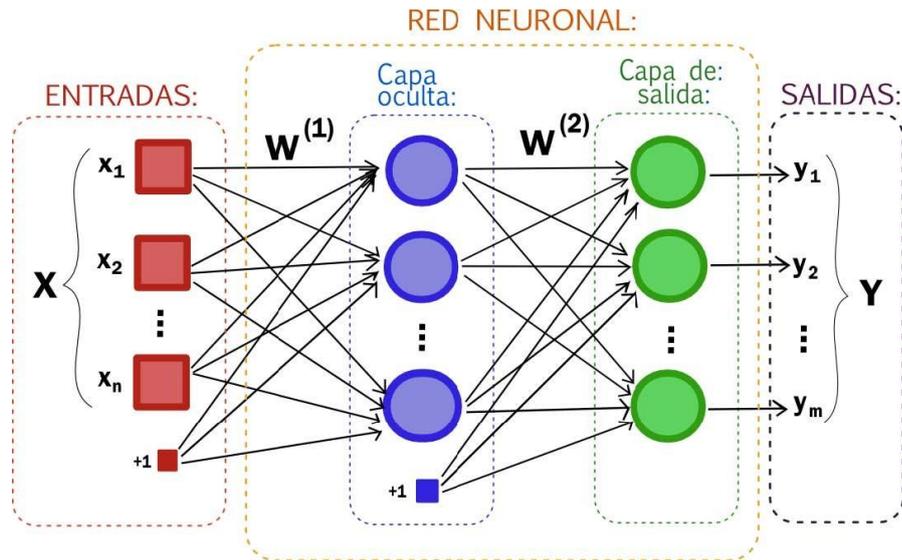
En la práctica, los modelos de regresión lineal se ajustan utilizando algoritmos estadísticos o técnicas de optimización para encontrar los valores óptimos de los coeficientes que minimizan la suma de los cuadrados de los residuos. Una vez que se ajusta el modelo, se puede utilizar para hacer predicciones sobre los valores de la variable dependiente para nuevas observaciones de las variables independientes (Montgomery, 2021)

Es importante tener en cuenta que, además de los coeficientes que ponderan las características del modelo, existen otros factores que pueden influir en el rendimiento y la generalización del modelo de regresión lineal. Estos factores, conocidos como hiperparámetros, incluyen la selección de características, la inclusión del término de intercepción y las opciones de optimización (Montgomery, 2021). La elección adecuada de estos hiperparámetros puede ser crucial para obtener un modelo de regresión lineal con un buen rendimiento predictivo y una buena capacidad de generalización.

Las redes neuronales, más complejas que los modelos lineales, pueden superar la linealidad modelada para la relación entre variables a través de utilizar una función de

activación. Por esta razón, se utilizan funciones de activación alternativas como la sigmoide, RELU o escalonada, lo que permite la generación de regresiones no lineales (Goodfellow, 2016).

Figura 8: Diagrama de Red Neuronal



Fuente: Imagen obtenida de Modelado y simulación del Robot Mitsubishi RV-2JA controlado mediante señales electromiografías, por Moya Marcelo, 2018, Universidad internacional de Ecuador.

En la figura 8 se puede observar cómo en una red neuronal, las neuronas se organizan en capas, y cada conexión entre neuronas tiene asociado un peso que determina la fuerza de la conexión. La relación entre las neuronas de una capa  $i$  y la capa siguiente  $j$  se expresa mediante la siguiente fórmula general:

$$z_j = \sum_{i=1}^n w_{ij}x_i + b_j \quad (3)$$

donde  $z_j$  es el potencial postsináptico de la neurona,  $w_{ij}$  es el peso asociado a la conexión entre la neurona  $i$  de la capa actual y la neurona  $j$  de la capa siguiente.  $x_i$  es la salida de la neurona  $i$  de la capa actual y  $b_j$  es el sesgo de la neurona  $j$ .

La salida de la neurona  $j$  se obtiene aplicando una función de activación  $f(\cdot)$  al potencial postsináptico:  $a_j = f(z_j)$ . Este proceso se repite para cada neurona en la capa siguiente. Las capas se pueden apilar, dando lugar a una estructura de red más compleja con capa de entrada, capa de salida y capas ocultas. La relación entre las neuronas puede representarse mediante una matriz de pesos  $w$ , donde  $w_{ij}$  representa el peso entre la

neurona  $i$  de la capa actual y la neurona  $j$  de la capa siguiente. La relación entre neuronas se determina por el signo del peso  $w_{ij}$ . Si  $w_{ij}$  es positivo, indica una relación excitadora, y si es negativo, la relación es inhibitoria (Nielsen, 2015).

Un último aspecto por destacar es el proceso de aprendizaje de las redes neuronales artificiales. Para eso se utiliza el sistema de propagación hacia atrás o *Backpropagation*, este algoritmo comienza con la comparación entre las predicciones de la red y los valores reales para calcular el error. Luego, este error se propaga hacia atrás a través de la red, ajustando los pesos de las conexiones para minimizar el error.

En el *Backpropagation* se realiza primero la inferencia hacia adelante para obtener las predicciones de la red (Goodfellow, 2016). Si la salida de la red es  $\hat{y}_i$  para la neurona  $i$  y la etiqueta correspondiente es  $y_i$ , después se calcula el error para la capa de salida utilizando una función de pérdida, siendo esto la media del error cuadrático (MSE):

$$MSE = \frac{1}{2}(Y_i - \hat{y}_i)^2 \quad (4)$$

A partir de la ecuación (4), se calcula la derivada parcial del error respecto a las salidas de la capa de salida  $\frac{\partial MSE}{\partial \hat{y}_i}$ . Esta es utilizada para actualizar los pesos y sesgos en la capa de salida. A continuación, se hace la propagación hacia atrás, derivando el error con respecto al potencial postsináptico ( $\frac{\partial E}{\partial z_i}$ ), utilizando la regla de la cadena:

$$\frac{\partial E}{\partial z_i} = \frac{\partial E}{\partial \hat{y}_i} \cdot \frac{\partial \hat{y}_i}{\partial z_i} \quad (5)$$

En la ecuación (5), la derivada  $\frac{\partial \hat{y}_i}{\partial z_i}$  es la derivada de la función de activación aplicada al potencial postsináptico. Se procede a actualizar los pesos, utilizando el descenso del gradiente:

$$w_{ij} \leftarrow w_{ij} - \eta \frac{\partial E}{\partial w_{ij}} \quad (6)$$

donde  $\eta$  es la tasa de aprendizaje. Los pasos anteriores se repiten para cada ejemplo de entrenamiento en varias iteraciones o épocas hasta que la red converge a un rendimiento deseado (Goodfellow, 2016).

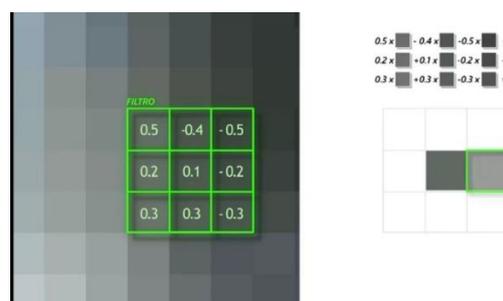
La propagación hacia atrás ajusta los pesos y sesgos en todas las capas de la red, permitiendo que esta aprenda de manera iterativa y mejore su capacidad para hacer predicciones más precisas (Nielsen, 2015). Es un proceso esencial en el entrenamiento efectivo de redes neuronales. Inspirados en la estructura y funcionamiento de las neuronas biológicas, estos modelos encuentran aplicaciones en el aprendizaje automático, desempeñando roles cruciales en el procesamiento del lenguaje natural, predicciones en diversos campos y especialmente en el reconocimiento de imágenes. Este último caso es abordado por un tipo específico de red neuronal conocida como redes neuronales convolucionales (Goodfellow, 2016).

### 2.2.2. Redes Neuronales Convolucionales

Las Redes Neuronales Convolucionales o *CNN*, representan una innovación destacada en el campo del aprendizaje profundo y han revolucionado la manera en que las computadoras pueden comprender e interpretar datos visuales (Artola, 2019). Diseñadas originalmente para tareas de visión por computadora, las *CNN* han demostrado una notable eficacia en una variedad de aplicaciones, desde la clasificación de imágenes hasta la detección de objetos y el reconocimiento facial. A diferencia de las redes neuronales tradicionales, las *CNN* incorporan capas convolucionales que permiten aprender patrones locales y jerárquicos en datos visuales de manera más eficiente.

Una *CNN*, se distingue por su utilización de capas que aplican una operación matemática llamada convolución. La convolución, aplicada a una imagen, es una operación que, manipulando los valores de los píxeles, genera otra imagen con características renovadas (Goodfellow, 2016). Específicamente, para generar cada píxel en la nueva imagen, se aplica una matriz numérica denominada filtro o *Kernel* sobre la imagen original. En este proceso, se multiplican y suman los valores de cada píxel vecino, resultando en un nuevo valor (Artola,2019). Esta operación se extiende a lo largo de toda la imagen, dando como resultado una nueva representación visual con píxeles transformados.

Figura 9: Filtro en una CNN,



Fuente: Imagen obtenida de *YouTube*, del canal *DotCSV*.

La figura 9 muestra un filtro en una imagen. En ella se puede observar el filtro representado en color verde con ciertos valores. Estos valores después se suman entre si generado un nuevo valor. Este proceso se realiza moviendo el filtro pixel a pixel para generar nuevos valores, siendo lo que se denomina convolución. La operación de convolución discreta se define como:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) \cdot K(m, n) \quad (7)$$

donde  $I(i, j)$  es el valor del pixel en la posición  $(i, j)$  de la imagen de entrada,  $K(m, n)$  es el valor del Kernel en la posición  $(m, n)$  y  $S(i, j)$  es el valor resultante después de aplicar la convolución.

A la ecuación (7), se le aplica una función de activación para introducir no linealidad en la red. Una función común es la *Rectified Linear Unit* (ReLU), definida como:

$$ReLU(x) = \max(0, x) \quad (8)$$

Al aplicar la función (8) se obtiene como resultado un mapa de características. Cada filtro produce un mapa de características diferente, resaltando distintas características de la imagen original (Artola, 2019). Formalmente, un mapa de características  $C$  se calcula como:

$$C(i, j) = f(\sum_m \sum_n I(i - m, j - n) \cdot K(m, n) + b) \quad (9)$$

donde  $f(\cdot)$  es la función de activación y  $b$  es el sesgo asociado al filtro.

Después de tener los mapas de características se realiza el cambio de resolución. Las capas de agrupación reducen la dimensionalidad de la representación y ayudan a hacer que la red sea más invariante a pequeñas traslaciones. La operación de agrupación comúnmente utilizada es el *Max Pooling*, que selecciona el valor máximo en una región:

$$MaxPooling(x) = \max(region) \quad (10)$$

Luego de varias capas de convolución y agrupación, se pueden agregar capas totalmente conectadas para realizar tareas más complejas (Goodfellow, 2016). La salida de estas capas se calcula como:

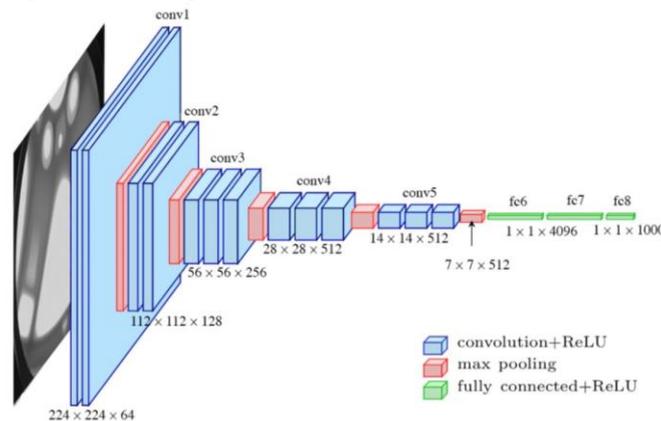
$$FC(x) = Wx + b \quad (11)$$

donde  $W$  es un vector de los pesos,  $x$  es el vector de entrada y  $b$  es el sesgo. Para entrenar la red, se utiliza una función de pérdida para cuantificar la discrepancia entre las predicciones y las etiquetas reales. Una función común es la Entropía Cruzada:

$$CrossEntropy(y, \hat{y}) = - \sum_i y_i \cdot \log(\hat{y}_i) \quad (12)$$

donde  $y$  son las etiquetas reales y  $\hat{y}$  son las predicciones.

Figura 10: Diagrama de Red Neuronal Convolutiva



Fuente: Imagen obtenida de Transfer learning en la clasificación binaria de imágenes térmicas transfer learning for binary classification of thermal images. Mach. Learn., 550(26), 4., Pérez-Aguilar (2021).

La Figura 10 ilustra el proceso de una red convolutiva. Cada cuadro azul en la figura corresponde a un mapa de características. A continuación, los cuadros rojos indican el cambio de resolución, mientras que los cuadros verdes representan la agrupación de capas.

Para entrenar la red, se utiliza el descenso del gradiente. Durante el *backpropagation*, se calculan las derivadas parciales de la función de pérdida con respecto a los pesos de la red, y se actualizan los pesos en la dirección opuesta al gradiente. Estas fórmulas representan de manera simplificada el funcionamiento básico de las CNN (Pérez, 2021). El éxito de las CNN radica en su capacidad para aprender jerarquías de características

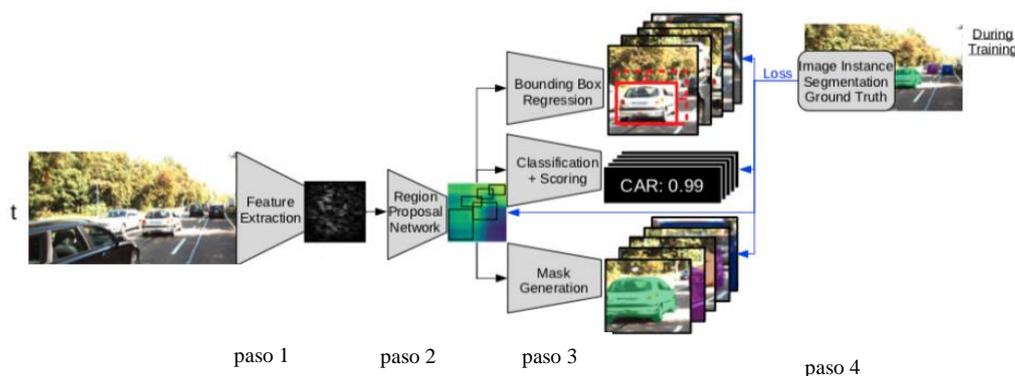
locales y globales, permitiendo así el procesamiento efectivo de datos estructurados como imágenes. Estas capas convolucionales, junto con capas de agrupación y capas totalmente conectadas, constituyen la arquitectura distintiva de las CNN, destacándolas como una herramienta esencial en la era actual de análisis de imágenes y reconocimiento visual avanzado.

En las siguientes secciones, se explorarán dos importantes arquitecturas en el campo de la visión por computadora basadas en Redes convolucionales: *Mask R-CNN* y YOLO (*You Only Look Once*), específicamente las versiones YOLOv4 y YOLOv5. Estos modelos son reconocidos por sus contribuciones en la detección y segmentación de objetos en imágenes. *Mask R-CNN*, una extensión del modelo *Faster R-CNN*, sobresale por su capacidad de detectar objetos y generar máscaras detalladas que rodean cada objeto identificado. Por otro lado, YOLOv4 y YOLOv5 son versiones mejoradas y avanzadas del modelo YOLO, conocidas por su eficiencia y precisión en la detección de objetos en tiempo real.

### 2.2.2.1 Mask R-CNN

*Mask R-CNN* (*Region-based Convolutional Neural Network*) es una arquitectura de red neuronal desarrollada para tareas de detección de objetos y segmentación de instancias, lo que significa que no solo identifica la presencia de objetos, sino que también segmenta cada instancia de esos objetos (He *et al.*, 2017).

Figura 11: Estructura de Mask R-CNN



Fuente: Imagen tomada de Proceedings of the IEEE international conference on computer vision, 2017, S. 2961–2969. He, Kaiming

La figura 11 muestra la arquitectura de una *Mask R-CNN*. En primer lugar, se encuentra el *Backbone model* o *Feature extraction*, que se refiere a la parte principal o central de la red. El *Backbone* es la arquitectura base que se utiliza para extraer características de las imágenes de entrada (He *et al.*, 2017). El *Feature extraction* puede ser una red preentrenada y se denota como  $F$ . Con la información del paso 1 se genera una *Region Proposal Network* (RPN). La RPN toma la salida del *Backbone*  $F$  y produce propuestas  $P$  que indican las ubicaciones probables de objetos en la imagen. La función de regresión y clasificación de la RPN se define como:

$$P_{bbox} = \text{Regresion}(F) \quad (13)$$

$$P_{cls} = \text{Clasificacion}(F) \quad (14)$$

donde  $P_{bbox}$  son las propuestas de cajas delimitadoras y  $P_{cls}$  son las probabilidades de clasificación.

Las propuestas generadas por la Red de Propuestas de Regiones se emplean para extraer regiones de interés (ROI Align) de la salida del Backbone, como sugiere He (2017). El *ROI Align* es una técnica que permite mapear estas regiones a una cuadrícula fija en la que se pueden realizar operaciones de *Pooling* sin pérdida de información. Su fórmula es:

$$X_{ROI} = \text{RoI Align}(F, P_{bbox}) \quad (15)$$

Por cada ROI, la red se divide en 3 ramas: una encargada de generar una *bounding box*, otra para decir a qué clase pertenece el objeto que aparece y con qué probabilidad, y otra que genera una máscara a nivel de píxel, siendo estas sus formulas

$$P'_{bbox} = \text{Regresion}_{bbox}(X_{ROI}) \quad (16)$$

$$P'_{cls} = \text{Clasificacion}_{cls}(X_{ROI}) \quad (17)$$

$$M_{mask} = \text{Mascara}(x_{ROI}) \quad (18)$$

Hay 2 conceptos importantes a mencionar en este tipo de red, la pérdida total y la optimización. La pérdida total  $L$  se define como la suma de las pérdidas de la  $RPN$ . Por otro lado, para su optimización la red se entrena minimizando la pérdida total mediante algoritmos de optimización como el descenso del gradiente. La *Mask R-CNN* entonces tiene capacidad para dividir la imagen en regiones y, luego, asignar máscaras a cada región donde se encuentra un objeto detectado. Esto permite no solo identificar qué objetos están presentes en la imagen, sino también delimitar con precisión las áreas correspondientes a cada objeto detectado (He *et al.*, 2017).

Figura 12: Modelo *Mask R-CNN* detectando la marca PedidosYa



Fuente: Elaboración propia a partir de imagen obtenida en Google con Python

La Figura 12 representa el resultado obtenido al crear un modelo destinado a detectar tanto el nombre como el logotipo de PedidosYa, utilizando el modelo *Mask R-CNN*. La elaboración de este modelo se basó en un conjunto de datos conformado por 22 imágenes de prueba y 5 de test, demandando un total de 26 horas de entrenamiento para su procesamiento integral. Sin embargo, con la finalidad de reducir significativamente los tiempos de procesamiento, dado que se busca añadir múltiples marcas al modelo en un breve lapso, idealmente en menos de 2 horas, se ha optado por realizar pruebas adicionales utilizando el modelo YOLO.

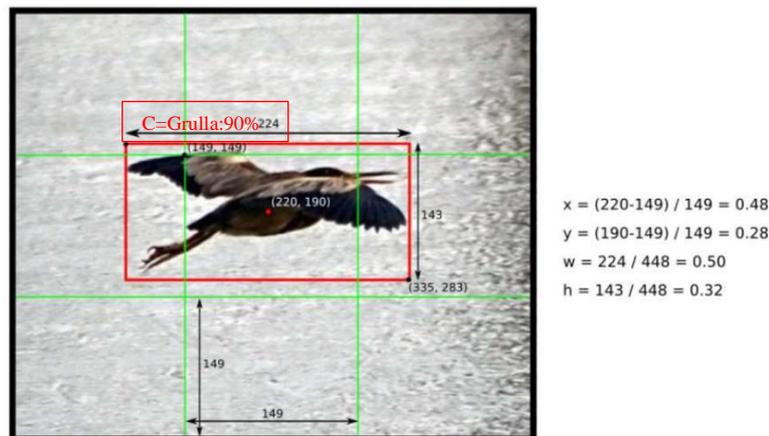
#### 2.2.2.2 YOLO

YOLO (*You Only Look Once*) es una arquitectura de red neuronal convolucional (CNN) popular utilizada para la detección de objetos en imágenes en tiempo real. Desarrollada por Joseph Redmon y Ali Farhadi, YOLO es conocida por su eficiencia y velocidad al realizar la detección de objetos en una sola pasada por la imagen completa. La

arquitectura YOLO divide la imagen de entrada en una cuadrícula y predice cajas delimitadoras y probabilidades de clase para los objetos en cada celda de la cuadrícula.

La imagen de entrada se divide en una cuadrícula de dimensiones  $S \times S$ . Cada celda de la cuadrícula es responsable de predecir cajas delimitadoras y probabilidades de clase para los objetos presentes en esa región (Redmon, 2016). Para cada celda de la cuadrícula, YOLO predice B cajas delimitadoras. Cada caja se caracteriza por 5 valores:  $x, y, w, h, c$

Figura 13: coordenadas del cuadro de una imagen en YOLO



Fuente: Imagen tomada de Estudio de la arquitectura YOLO para la detección de objetos mediante *Deep Learning*, Rozada, 2021.

En la figura 13 es posible observar cómo  $x$  y  $y$  son las coordenadas del centro de la caja con respecto a las dimensiones de la celda.  $w$  y  $h$  son el ancho y alto normalizados de la caja con respecto al tamaño de la imagen (Redmon, 2016).  $C$  representa la confianza de la predicción (probabilidad de que haya un objeto en la caja). La fórmula para calcular las coordenadas absolutas de la caja en la imagen es:

$$CA = (CR \times T) + PC \quad (19)$$

donde  $CA$  es coordenada absoluta,  $CR$  coordenada relativa,  $T$  es Tamaño de celda y  $PC$  es posición de la celda. Para cada caja, YOLO predice las probabilidades de pertenencia a diferentes clases  $P(\text{clase} / \text{objeto})$ . La fórmula es:

$$P(\text{clase} | \text{objeto}) = \sigma(\text{puntuacion de clase}) \quad (20)$$

donde  $\sigma$  es la función de activación sigmoide. Después se calcula la confianza final de una caja (Confianza final), esta combina la confianza de la predicción ( $c$ ) con la probabilidad máxima de clase  $P(\text{clase} \mid \text{objeto})$ :

$$\text{Confianza final} = c \times P(\text{clase} \mid \text{objeto}) \quad (21)$$

Para mitigar la generación de predicciones redundantes, YOLO incorpora *Non-Maximum Suppression* (NMS) (Neubeck *et al.*, 2006). Este algoritmo, comúnmente utilizado en el procesamiento de imágenes, se encarga de organizar la lista de detecciones según sus puntuaciones, comenzando con la detección de mayor puntuación. Luego, examina las detecciones restantes que se superponen con la actual; si la detección actual tiene una puntuación superior a las detecciones superpuestas, se retiene; de lo contrario, se descarta la detección superpuesta. Este proceso se repite iterativamente, asegurando la retención de las predicciones más confiables y eliminando aquellas que presentan superposiciones significativas.

La pérdida total de YOLO se conforma de tres componentes principales que se utilizan para entrenar el modelo y mejorar su rendimiento en la detección de objetos en imágenes. Según Redmon *et al.* (2016), estas componentes son la pérdida de coordenadas, la pérdida de confianza y la pérdida de clase. La pérdida de coordenadas se refiere a la discrepancia entre las coordenadas predichas por el modelo y las coordenadas reales de los cuadros delimitadores alrededor de los objetos en la imagen. Como especifica Redmon *et al.* (2016), esta componente mide qué tan precisa es la predicción del modelo en términos de la posición y el tamaño de los objetos detectados.

Por otro lado, la pérdida de confianza evalúa la certeza o confianza que tiene el modelo en sus predicciones, según lo explicado por Redmon *et al.* (2016). Se trata de la discrepancia entre la probabilidad asignada por el modelo a la presencia de un objeto en un cuadro delimitador y la probabilidad real de que ese objeto esté presente en esa región de la imagen. Finalmente, la pérdida de clase se centra en la precisión de la clasificación de los objetos detectados en la imagen, según lo indicado por Redmon *et al.* (2016). Esta componente mide la discrepancia entre las clases predichas por el modelo y las clases reales de los objetos en la imagen.

Lo que distingue a YOLO es su enfoque "*you only look once*" que implica que el modelo analiza la imagen completa de manera integral, en lugar de dividirla en regiones y luego

realizar predicciones en esas secciones individuales (Redmon, 2016). Este enfoque permite una detección más rápida al tiempo que mantiene una buena precisión en la identificación de objetos, identificando múltiples objetos en una sola imagen, asignando una etiqueta y delimitando con cajas de manera eficiente. Existen diferentes versiones de YOLO. A continuación, se exploran las versiones 4 y 5.

#### **2.2.2.2.1. YOLOv4**

YOLOv4 es una versión mejorada y avanzada de la arquitectura de detección de objetos YOLO. Desarrollada por Alexey Bochkovskiy, Chien-Yao Wang y Hong-Yuan Mark Liao, esta versión presenta mejoras significativas sobre las versiones anteriores en términos de precisión y velocidad en la detección de objetos en imágenes. Las mejoras en YOLOv4 incluyen cambios en la arquitectura de la red neuronal convolucional, la implementación de bloques más eficientes y la integración de módulos de atención espacial lo que permite que el modelo capture información contextual a diferentes escalas y niveles de detalle en la imagen (Bochkovskiy *et al.*, 2020).

En YOLOv4, se aplican diversas técnicas para mejorar el rendimiento del modelo, como la normalización de datos, el aumento de datos y la optimización de hiperparámetros. El aumento de datos en este contexto se refiere a la estrategia de generar nuevas instancias de datos de entrenamiento mediante la aplicación de transformaciones aleatorias a las imágenes existentes (Bochkovskiy *et al.*, 2020). Por ejemplo, se pueden realizar rotaciones, recortes, cambios en el brillo o la saturación, entre otros, con el fin de aumentar la diversidad del conjunto de datos y mejorar la capacidad del modelo para generalizar a nuevas imágenes. Este procedimiento ayuda a prevenir el sobreajuste y a mejorar la robustez del modelo frente a diversas condiciones de iluminación, ángulos de visión y variaciones en los objetos detectados.

Optimizar hiperparámetros se refiere al proceso de encontrar la combinación más efectiva de valores para estos en un modelo de aprendizaje automático. Los hiperparámetros son configuraciones que no se aprenden directamente del entrenamiento del modelo, a diferencia de los parámetros del modelo, como los pesos en una red neuronal. En cambio, los hiperparámetros son configuraciones que controlan el proceso de entrenamiento y la estructura del modelo (Villalobos-Arias *et al.*, 2021).

Figura 14: Modelo YOLOv4 detectando la marca PedidosYa



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 14, se muestra el resultado del entrenamiento del modelo YOLOv4 durante un período de 2 horas. Aunque no se logra la detección de todas las marcas, es posible observar que identifica la bolsa que contiene el logo de la marca en un 38% (marcado en color rosa). Al prolongar el tiempo de entrenamiento, se observa una mejora considerable, ya que casi la totalidad de las marcas son detectadas. Sin embargo, a pesar de estos resultados, su rendimiento no supera al del modelo *Mask R-CNN*. Con el objetivo de obtener mejores resultados en un tiempo de entrenamiento similar, se ha optado por probar YOLOv5.

#### 2.2.2.2.2. YOLOv5

YOLOv5 es una arquitectura de detección de objetos desarrollada por Glenn Jocher, desarrollador principal de *Ultralytics*. Esta versión continúa la línea de modelos YOLO. A diferencia de su versión anterior, YOLOv5 utiliza una arquitectura basada en redes neuronales convolucionales y presenta una estructura de red más simple, lo que facilita su implementación y entrenamiento. Además, utiliza métodos de aumento de datos más avanzados para mejorar el rendimiento en la detección de objetos.

En comparación con YOLOv4, YOLOv5 introduce algunas mejoras en los métodos de aumento de datos para mejorar aún más el rendimiento del modelo. YOLOv5 implementa el aumento de datos mediante el entrenamiento con imágenes de alta resolución (por ejemplo, 640x640 y 1280x1280) y la escala de imágenes durante el entrenamiento y la inferencia (Jocher *et al.*, 2022). Esto permite al modelo capturar detalles finos de los

objetos y mejorar la precisión de la detección, especialmente para objetos pequeños o distantes.

Además, YOLOv5 aplica una variedad de transformaciones aleatorias de distorsión de datos, como rotaciones, recortes, cambios de brillo, cambios de contraste, cambios de saturación y cambios de tono (Jocher *et al.*,2022). Estas transformaciones se aplican de manera aleatoria a las imágenes de entrada durante el entrenamiento para aumentar la variabilidad y diversidad del conjunto de datos y mejorar la capacidad del modelo para generalizar a diversas condiciones.

Figura 15: Modelo YOLOv5 detectando la marca PedidosYa



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 15 se presenta el resultado del entrenamiento del modelo YOLOv5, el cual cumple con las expectativas al detectar todas las marcas en un lapso de menos de 2 horas. Logra detectar los 2 logos de PedidosYa con color rosa claro (74% y 77% respectivamente) y el nombre de la marca en color naranja (66% y 57% respectivamente). Esta capacidad de detección eficiente facilita la escalabilidad y la adición sencilla de nuevas marcas al modelo. Con este resultado satisfactorio, se procede a aplicar este modelo al video de la marca, obteniendo información relevante que previamente no estaba disponible.

### 2.3. Información proporcionada por el modelo YOLOv5

Al aplicar el modelo YOLOv5 al vídeo, se obtiene información significativa que, junto con la presencia de la marca, puede ayudar a comprender y mejorar el rendimiento de la publicidad. Esta información adicional resulta esencial para comprender de qué manera se puede optimizar la estrategia publicitaria. El análisis proporcionado permite identificar

aspectos clave que podrían contribuir a mejorar la efectividad de futuras campañas publicitarias.

Figura 16: Información proporcionada por el modelo



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 16 se presenta el resultado de la aplicación del modelo YOLOv5 al video publicitario de PedidosYa. Se visualiza la detección en cada *frame*, mostrando específicamente los cuadros de detección de la marca, cuyas probabilidades asociadas son 96% y 77% respectivamente (como se indica en rosa). Esta información detallada no solo proporciona la ubicación precisa de la detección, sino que también permite extraer datos adicionales relevantes para un análisis más profundo.

Al determinar la posición de las marcas, es viable realizar un seguimiento de sus apariciones simultáneas, denominadas como clúster, que representa la cantidad de marcas visibles en la pantalla, considerando el recuento total como las marcas únicas presentes. Luego, se lleva a cabo la división del número de marcas por cada *frame* para un análisis más detallado.

Figura 17: Clasificación de número de cuadros y marcas por *frame* del modelo



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 17 se ilustra el conteo específico de marcas por *frame*. En este ejemplo, se detectan dos instancias del nombre de PedidosYa (en rosa), lo que representa una única marca con dos apariciones. Por ende, en este *frame* en particular, el clúster es de 0,5.

El modelo *YOLO*, además de señalar el punto central, proporciona las coordenadas superiores (x e y) para determinar la altura y anchura de la imagen. Esto posibilita el cálculo preciso del tamaño de la imagen, permitiendo contar cada píxel individualmente.

Figura 18: Tamaño de la marca en cada *frame*



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 18, se muestra el tamaño de la marca considerando el recuento de píxeles, lo que evidencia que el rectángulo rosa del lado izquierdo es mayor al tener una mayor cantidad de píxeles enmarcados (10.500 píxeles en contraposición a 2.058 del lado derecho).

El seguimiento del conteo de apariciones de marcas en cada fotograma del video permite medir con precisión el tiempo de exposición de cada marca. Esta métrica es fundamental en la industria publicitaria, ya que, al auditar anuncios televisivos, se valora y mide la duración exacta de la presencia de una marca en pantalla. Esta medición, se utiliza para calcular los *TRPs* (Rating de Puntos porcentuales de Televisión), que representan el porcentaje de audiencia que se expone a un anuncio en particular durante un periodo determinado de tiempo (Katz, 2016). Los TRPs son un indicador clave para evaluar la efectividad y la eficacia de una campaña publicitaria televisiva, ya que cuantifican la exposición potencial del público a un anuncio específico (Abele y Stone, 1974).

Figura 19: Duración de la marca en pantalla



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 19 se presenta el recuento total de *frames* acumulados, lo cual permite obtener mediciones precisas en segundos. En este ejemplo en particular, se contabilizan 168 *frames*, y dado que el video tiene una frecuencia de 25 fotogramas por segundo, esto equivale a una duración de 6,72 segundos.

Dado que se cuenta con la detección del punto central de la imagen y se conoce que el punto central en todos los *frames* es 640 x 360 (para un video con 1280 x 720 pixeles), es factible calcular la distancia al centro en cada *frame* donde se detecta la marca. Este cálculo se realiza aplicando el teorema de Pitágoras, mediante la siguiente fórmula:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (22)$$

Figura 20: Distancia al centro de la marca



Fuente: Elaboración propia como resultado de aplicar el modelo con Python

En la Figura 20 se muestra el resultado tras aplicar el teorema de Pitágoras, revelando una distancia de 235,46 *pixels* entre el punto central de la imagen y el punto central del *frame*. Luego de recopilar los datos de los *frames* en su totalidad, se procede a analizar individualmente cada imagen donde se detecta la marca. Este análisis se realiza para identificar los colores presentes en estas imágenes específicas y así contrastarlos con los colores de los *frames* generales.

Figura 21: Color de la marca



Fuente: Elaboración propia a partir del video de la marca alojado en *YouTube* con Python

En la Figura 21 se exhibe un ejemplo específico de los colores particulares identificados en la marca detectada, evidenciando un contraste entre tres colores distintivos: rojo, verde y azul.

La precisión de la detección de la marca en términos de sus coordenadas exactas, la probabilidad de aparición y el número de detecciones por *frame* proporciona una visión cuantitativa y cualitativa de su presencia en el material audiovisual. Estos datos cuantificables permiten evaluar la exposición real y la prominencia de la marca en pantalla, lo que es fundamental para entender su visibilidad y su impacto potencial en la audiencia. Asimismo, el análisis del tamaño de la marca y la duración de su presencia en pantalla brinda información sobre su relevancia y persistencia en el contenido, factores críticos para determinar su efectividad publicitaria.

La medición de la distancia al centro de la imagen donde se localiza la marca y el análisis de los colores utilizados en su representación contribuyen a comprender cómo la marca se integra visualmente en la escena. Estos detalles no solo ofrecen una perspectiva espacial y cromática, sino que también influyen en la percepción y el recuerdo de la marca por parte de la audiencia. El conocimiento de estos aspectos proporciona información crucial para evaluar la integración natural de la marca en el contenido y su posible impacto emocional y cognitivo en los espectadores.

En conjunto, estas métricas y detalles no solo ofrecen un análisis exhaustivo de la presencia de la marca, sino que también proporcionan *insights* valiosos sobre su visibilidad, impacto visual y temporal, así como su integración en el contexto mediático. Estos elementos son esenciales para evaluar la efectividad del *Product Placement*, permitiendo a las organizaciones comprender mejor cómo su marca es percibida y recordada por la audiencia en un entorno altamente visual y competitivo.

## **Conclusión**

En el presente capítulo, se logró determinar la importancia de la recolección y análisis de datos no estructurados en el ámbito del *Product Placement*, destacando su papel

fundamental en la comprensión y evaluación de la presencia de productos en contextos visuales. Esta exploración ha resaltado la necesidad imperante de examinar detalladamente la inserción de productos en estos contextos mediante la recolección, análisis y procesamiento de datos no estructurados, lo que emerge como un aspecto esencial para el diseño efectivo de estrategias de *Marketing* en el ámbito del entretenimiento y los medios visuales.

Partiendo de la comprensión del video como una secuencia de imágenes, se ha puesto énfasis en la relevancia de desentrañar la información contenida en cada *Frame*, comprendiendo aspectos cruciales como la distribución de píxeles y la variedad cromática presente en la imagen. Esta exploración inicial sienta las bases para una comprensión más holística y detallada de la exposición de productos en entornos visuales, proporcionando una visión más profunda de la dinámica de las estrategias de *Product Placement*. Sin embargo, información disponible en un video va más allá de la distribución de píxeles y la gama cromática, lo que requiere un análisis más profundo para desentrañar todos los aspectos relevantes que puedan influir en la efectividad de las estrategias de colocación de productos.

Tras la obtención de los datos iniciales derivados del análisis de imágenes, se procede a un análisis más específico mediante el desarrollo de modelos de visión por computadora, los cuales posibilitan una comprensión más profunda del contenido visual. Estos modelos están basados en la implementación de redes neuronales, y en particular, se han evaluado dos modelos específicos: Mask R-CNN y YOLO. Aunque Mask R-CNN puede ofrecer una mayor precisión en determinadas circunstancias, su implementación tiende a requerir más tiempo de desarrollo y conlleva dificultades al intentar expandir su capacidad para adaptarse a un mayor número de marcas personalizadas. Por consiguiente, se determina que YOLO es la mejor elección para el análisis y detección de marcas en imágenes personalizadas.

Después de aplicar el modelo YOLO en su versión 5, se logra identificar información adicional previamente no detectada, lo que permite una detección más precisa de marcas en el contexto del *Product Placement*. Este análisis, aborda aspectos como el tamaño, la posición espacial y la relación entre marcas en *Frames* compartidos. Estos aspectos pueden influir en el diseño estratégico de *Product Placement* en organizaciones al proporcionar una comprensión más profunda del entorno visual. La gestión eficiente de

estos datos no estructurados desempeña un papel fundamental en la optimización de las estrategias de *Product Placement* al permitir una adaptación más precisa de las tácticas utilizadas, lo que potencializa la efectividad de las campañas implementadas. Este análisis detallado de datos visuales proporciona una base sólida para la toma de decisiones fundamentadas, contribuyendo así a mejorar el rendimiento y el impacto de las estrategias de colocación de productos.

Esta comprensión detallada de la presencia de marcas en medios visuales, combinada con variables de respuesta como la interacción por parte de los usuarios, impulsa una toma de decisiones más estratégica y fundamentada en datos en el ámbito del *Marketing* y la publicidad. La integración de estas variables será abordada en el siguiente capítulo, lo que permitirá una perspectiva más completa y una aplicación más efectiva de estrategias de colocación de productos.

### **Capítulo 3: Puntos de contacto en el *Product Placement* y modelos de optimización de la visualización**

#### **Introducción**

En la actualidad la información se ha consolidado como un recurso fundamental para las organizaciones (Castells, 2006). En este entorno altamente competitivo, la evolución hacia un modelo basado en datos ha marcado una transformación significativa en las estrategias de *Marketing* (Jeffery, 2010). La gestión de datos no estructurados se revela como un pilar esencial en esta revolución, permitiendo a las organizaciones extraer *insights* valiosos de fuentes que van desde interacciones en redes sociales hasta análisis de videos. Este cambio de paradigma no solo impulsa la toma de decisiones estratégicas, sino que también optimiza los procesos internos, ofreciendo una comprensión más profunda del comportamiento del consumidor (Armstrong y Kotler, 2003). La capacidad de adaptarse a este entorno, donde los datos no estructurados son cada vez más predominantes, se vuelve crucial para la eficacia y la relevancia en el mercado actual.

En el contexto del *Product Placement*, la relevancia de comprender la influencia de las estrategias de detección de puntos de contacto en la experiencia visual de los consumidores adquiere una importancia crucial (Jeffery, 2010). En un escenario donde los consumidores están constantemente expuestos a una multiplicidad de estímulos visuales, la identificación precisa de los puntos de contacto se convierte en un factor

determinante para evaluar la efectividad de las estrategias de colocación de productos (Rodríguez, 2016). La interacción visual de los consumidores con productos insertados en contenidos mediáticos se convierte en un campo de estudio esencial para comprender su comportamiento y sus preferencias (Morgado, 2007). Entender de manera eficaz a los usuarios, comprendiendo de qué forma perciben los estímulos visuales, ayuda a optimizar el tiempo de exposición de la colocación de productos, generando una mayor visibilidad de la marca.

En el dinámico mundo del *Marketing* contemporáneo, el enfoque en la optimización de la visualización de la marca se ha vuelto una prioridad fundamental para las organizaciones que buscan maximizar el impacto de sus estrategias comerciales (Smith y Brown, 2018). Dentro de este panorama, el *Marketing* de contenido ha emergido como una poderosa herramienta para involucrar a los consumidores y promover marcas de manera efectiva (Hanna *et al.*, 2011). Sin embargo, para lograr el máximo rendimiento de estas iniciativas, es crucial comprender cómo las estrategias de *Product Placement* pueden influir en la visibilidad de la marca y cómo se pueden mejorar mediante técnicas analíticas avanzadas.

En este contexto, surge la siguiente pregunta: ¿Cómo se puede optimizar la visibilidad de la marca en el *Marketing* de contenido mediante la predicción de la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual, empleando un modelo de clasificación óptimo? Con el propósito de responder a esta interrogante, en el presente capítulo se abordará la dinámica de los puntos de contacto en el *Product Placement* desde la perspectiva de los consumidores. El análisis se estructura en tres secciones que buscan proporcionar una comprensión integral de la interacción visual, la relevancia en el contexto del *Marketing* organizacional y la efectividad de las estrategias para mejorar el tiempo de exposición de los productos, que permitirán optimizar la visibilidad de la marca.

En la primera sección, se abordará la metodología empleada para la identificación de puntos de contacto por parte de los consumidores. Se presentarán herramientas específicas como *WebGazer.js* y *Gaze recorder*, destacando cómo estas tecnologías contribuyen a la detección efectiva de la interacción visual. Esta sección proporcionará una base para comprender cómo se recopila y procesa la información visual en el contexto del *Product Placement*. Adicionalmente se adentrará en la sincronización de puntos de

contacto visual, destacando la metodología de recolección de información y la aplicación de técnicas como *K-Means*.

La segunda sección consolida la totalidad de los datos generados para construir un *Data Frame* que describirá de manera concisa y completa los datos recopilados. Seguidamente, se lleva a cabo la implementación de varios modelos con el objetivo de predecir la distancia entre los puntos de contacto y la aparición de la marca. Posteriormente, estos modelos serán evaluados para determinar su eficacia. Por último, en la tercera sección se seleccionará el modelo más adecuado, se analizarán detalladamente los resultados obtenidos y se explicará cómo estos resultados contribuyen a la optimización de la visualización de la marca.

### **3.1. Detección de puntos de contactos en el *Product Placement***

En el ámbito del *Product Placement*, la detección efectiva de puntos de contacto es crucial para entender la interacción visual de los consumidores con productos integrados en contenidos mediáticos (Jeffery, 2010). Las estrategias empleadas para esta detección tienen un impacto significativo en la calidad de los datos recopilados y la precisión del análisis. En este contexto, la elección de herramientas adecuadas y la implementación de metodologías efectivas se convierten en factores críticos para el éxito de esta estrategia.

En este marco, es esencial resaltar la importancia de seleccionar estrategias que no solo identifiquen los puntos de contacto, sino que también proporcionen una comprensión profunda de la atención visual de los consumidores (Kongmanon y Petison, 2022). La correcta aplicación de estas estrategias no solo contribuye a la obtención de datos precisos, sino que también facilita una interpretación acertada de la interacción visual (Ronft, 2023). La elección cuidadosa de herramientas especializadas y la implementación de métodos efectivos son, por tanto, elementos fundamentales que inciden directamente en la eficacia de la detección de puntos de contacto en el contexto del *Product Placement*.

La tecnología juega un papel destacado al proporcionar herramientas avanzadas capaces de capturar y analizar el comportamiento visual de los consumidores de manera no intrusiva (Rumpf, 2019). Estas herramientas facilitan la observación de la atención dirigida a productos específicos, lo que contribuye a una comprensión más detallada de cómo los consumidores interactúan visualmente con el contenido que presenta colocaciones de productos. La integración eficiente de estas tecnologías en la estrategia

para la detección de puntos de contacto es esencial para lograr resultados precisos y significativos en el análisis de la experiencia visual de la audiencia. A continuación, se muestran las metodologías probadas.

### **3.1.1. Metodologías para la detección de puntos de contactos**

Se evaluaron dos metodologías para detectar los puntos de contacto de los usuarios en el anuncio publicitario de PedidosYa: *WebGazer.js* y *Gaze Recorder*.

#### **3.1.1.1. WebGazer.js**

El seguimiento ocular en entornos web ha sido objeto de creciente interés debido a su potencial para mejorar la interacción humano-máquina en línea. En este contexto, el artículo "*WebGazer: Scalable Webcam Eye Tracking Using User Interactions*" (Papoutsaki *et al.*, 2016) presenta un enfoque novedoso y accesible para el seguimiento ocular utilizando la cámara web de un dispositivo. Los autores proponen el sistema *WebGazer*, diseñado para realizar seguimiento ocular en tiempo real mediante JavaScript y HTML5, sin requerir hardware adicional.

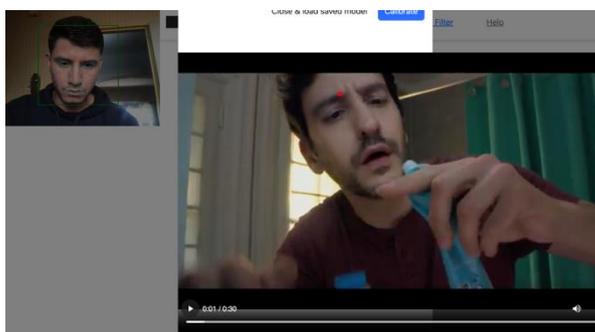
El sistema *WebGazer* se basa en dos componentes principales: un modelo de predicción de la mirada y un algoritmo de calibración. El modelo de predicción utiliza una red neuronal convolucional para estimar la dirección de la mirada a partir de una imagen de la cara del usuario (Papoutsaki *et al.*, 2016). La red neuronal se entrena en un conjunto de datos de imágenes de caras con anotaciones de la dirección de la mirada. El algoritmo de calibración se utiliza para ajustar el modelo de predicción a las características específicas del usuario. Esto se hace pidiendo al usuario que mire a una serie de puntos en la pantalla. El algoritmo utiliza las posiciones de los puntos de mirada para ajustar los parámetros del modelo de predicción (Papoutsaki *et al.*, 2016).

Las matemáticas del modelo de predicción se basan en una red neuronal convolucional con dos capas convolucionales y una capa completamente conectada, como los modelos presentados en el capítulo 2. La primera capa convolucional extrae características de la imagen de la cara, la segunda capa convolucional combina las características extraídas por la primera capa, y la capa completamente conectada utiliza las características combinadas por la segunda capa convolucional para estimar la dirección de la mirada. El algoritmo de calibración utiliza un algoritmo de mínimos cuadrados, como fue descrito en el capítulo 2, para ajustar los parámetros del modelo de predicción, minimizando la

diferencia entre las direcciones de la mirada predichas por el modelo y las direcciones de la mirada reales del usuario.

*WebGazer* es un sistema preciso, fácil de usar y no requiere hardware adicional, lo que lo hace ideal para una variedad de aplicaciones web, como interfaz de usuario por mirada, control de juegos, educación y accesibilidad (Papoutsaki *et al.*, 2016). El desarrollo de *WebGazer* está en curso, con investigaciones para mejorar la precisión del sistema y ampliar su rango de aplicaciones.

Figura 22: Visualización de *WebGazer.js*



Fuente: Elaboración propia a partir de la librería *WebGazer.js*

La Figura 22 presenta la aplicación de la herramienta en ordenador propio, exhibiendo una porción del proceso de calibración y el resultado obtenido. Se destaca un punto rojo que indica la dirección de la mirada. No obstante, se evidencia que el video no abarca la totalidad de la pantalla. Además, es relevante señalar que el movimiento del ojo, reflejado en el punto rojo, exhibe una velocidad más lenta que el movimiento real del ojo. Este desfase resulta en la generación de *frames* de retraso, lo que implica que la producción de información carece de precisión. Se procede a probar con la metodología *Gaze Recorder* con la intención de comparar resultados y utilizar la mejor.

### 3.1.1.2. *Gaze Recorder*

*Gaze Recorder* es una aplicación web que utiliza la cámara web del usuario para grabar y analizar el movimiento de sus ojos. El funcionamiento se basa en dos componentes principales: un rastreador ocular y un módulo de análisis, ambos con fundamentos matemáticos específicos. El rastreador ocular utiliza un algoritmo de detección de pupilas basado en la técnica de umbralización adaptativa y el método de mínimos cuadrados para

determinar la posición del centro de la pupila en cada imagen. La dirección de la mirada se calcula a partir de la posición de las pupilas y la posición de la cámara web.

La umbralización adaptativa es una técnica utilizada en procesamiento de imágenes y visión por computadora para segmentar regiones de interés en una imagen. La umbralización se refiere al proceso de convertir una imagen en una imagen binaria, donde los píxeles se clasifican como blancos o negros según si superan o no un cierto umbral de intensidad (González, 2017). Se utiliza la siguiente fórmula para calcular el umbral adaptativo:

$$T = \mu + k * \sigma \quad (23)$$

donde  $\mu$  es la media local de la intensidad de la imagen,  $\sigma$  es la desviación estándar local, y  $k$  es un parámetro ajustable.

Por su parte el módulo de análisis ofrece diversas herramientas para visualizar y analizar los datos de seguimiento ocular, como mapas de calor que se generan utilizando la técnica de interpolación de Shepard para estimar la densidad de fijaciones en cada punto de la pantalla. También, gráficos de dispersión que muestran la relación entre la posición de la mirada y otras variables, como el tiempo o la respuesta del usuario; y análisis de fijaciones que se realizan mediante la detección de picos en la velocidad de cambio de la posición de la mirada.

Para el presente análisis, es de interés el mapa de calor, pues será usado para reflejar los puntos de contactado de los individuos al anuncio de PedidosYa. La técnica de interpolación de Shepard es un método utilizado en el campo del análisis espacial y el procesamiento de datos geospaciales. Esta técnica se utiliza para estimar valores desconocidos en ubicaciones específicas dentro de un conjunto de datos dispersos, basándose en los valores conocidos y su proximidad espacial.

El método de interpolación de Shepard asigna un valor estimado a un punto de interés basado en una ponderación de los valores conocidos en función de su distancia al punto de interés. Los valores más cercanos tienen más influencia en la estimación que los valores más lejanos. Esta ponderación se realiza utilizando una función de distancia, que puede ser lineal, cuadrática, cúbica u otra función que disminuya a medida que aumenta la distancia (Osorio *et al.*, 2011).

La fórmula general para la interpolación de *Shepard* es:

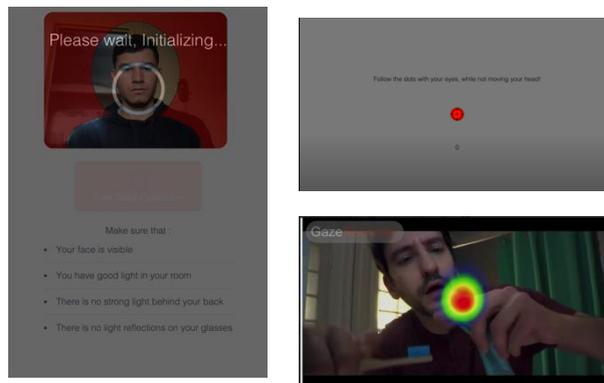
$$Z(u, v) = \frac{\sum_{i=1}^n \frac{Z_i}{d_i^p}}{\sum_{i=1}^n \frac{1}{d_i^p}} \quad (24)$$

donde  $Z(u, v)$  es el valor estimado en el punto de interés  $(u, v)$ ,  $Z_i$  son los valores conocidos en los puntos de datos  $i$ ,  $d_i$  es la distancia entre el punto de interés y el punto de datos  $i$  y  $p$  es un parámetro que controla la forma en que se ponderan las distancias.

La interpolación de *Shepard* permite estimar la posición precisa de los puntos oculares (como la pupila o los contornos del ojo) en ubicaciones no muestreadas dentro de un conjunto de datos de seguimiento ocular (Shen, 1993). El proceso implica tener un conjunto de datos de seguimiento ocular donde se conocen las posiciones de los puntos oculares en una serie de imágenes o fotogramas. Estos puntos se consideran como puntos de datos con valores conocidos (coordenadas  $x, y$ ) en el espacio bidimensional. Cuando se desea estimar la posición de un punto ocular en una ubicación no muestreada, se aplica la técnica de interpolación de *Shepard*. En este caso, los "valores conocidos" serían las posiciones de los puntos oculares en las imágenes disponibles, y la "distancia" podría ser la distancia euclidiana entre el punto de interés y los puntos conocidos.

Es fundamental subrayar que, aunque se realiza un seguimiento ocular personalizado, el uso de *Gaze Recorder* se adhiere estrictamente a las regulaciones de privacidad. Se solicita el consentimiento previo a todas las personas sujetas al seguimiento ocular, garantizando así la recopilación y el análisis de sus datos en total en conformidad con las políticas de privacidad.

Figura 23: Visualización de *Gaze Recorder*



Fuente: Página web de *Gaze Recorder*.<sup>5</sup>

En la Figura 23, se ilustra el proceso de calibración ocular en la página *web* de *Gaze Recorder*. Este proceso comienza con una pantalla inicial donde se solicita al usuario que ajuste su cabeza dentro de un área específica. Posteriormente, se procede con la calibración ocular, donde se realiza un seguimiento a patrones de puntos, finalmente se visualiza el contenido creativo de PedidosYa. Durante los 30 segundos de duración del anuncio, el espectador interactúa con el contenido de manera natural. Una vez finalizada la reproducción, se presenta en pantalla el mapa de calor generado a partir de los movimientos oculares del individuo.

Es importante destacar que el seguimiento ocular realizado en este proceso es preciso, capturando cada *frame* con exactitud. Esto permite un análisis detallado de los patrones de atención visual del usuario. Además, el video resultante se guarda para su posterior procesamiento mediante un modelo YOLOv5, que registra las coordenadas del ojo *frame* a *frame*. Este procedimiento se repite para cada individuo que visualice el video, ya que cada persona tiende a enfocarse en diferentes áreas de la pantalla. Por lo tanto, es necesario aplicar una metodología que permita alinear y unificar los puntos de interés en cada fotograma para un análisis coherente y preciso.

### **3.1.2. Sincronización de puntos de contacto visual en consumidores**

Para llevar a cabo una sincronización de puntos de contacto visual, resulta crucial determinar la cantidad de individuos que se utilizarán. En este caso específico, se decidió trabajar con una muestra compuesta por 20 participantes. Esta selección se fundamentó en una evaluación de factores logísticos, metodológicos y los objetivos de la investigación. La elección de una muestra más reducida facilitó notablemente tanto el proceso de reclutamiento como la recolección de datos, lo cual se alineaba con la necesidad de optimizar los recursos disponibles, tanto en términos de tiempo como de presupuesto.

Además, la muestra de 20 individuos se justificó en función de los objetivos específicos del estudio. Dado que el propósito principal era explorar patrones generales de comportamiento visual en un contexto determinado, una muestra de este tamaño se consideró adecuada para alcanzar dichos objetivos sin comprometer la calidad de los

---

<sup>5</sup> <https://gazerecorder.com/>

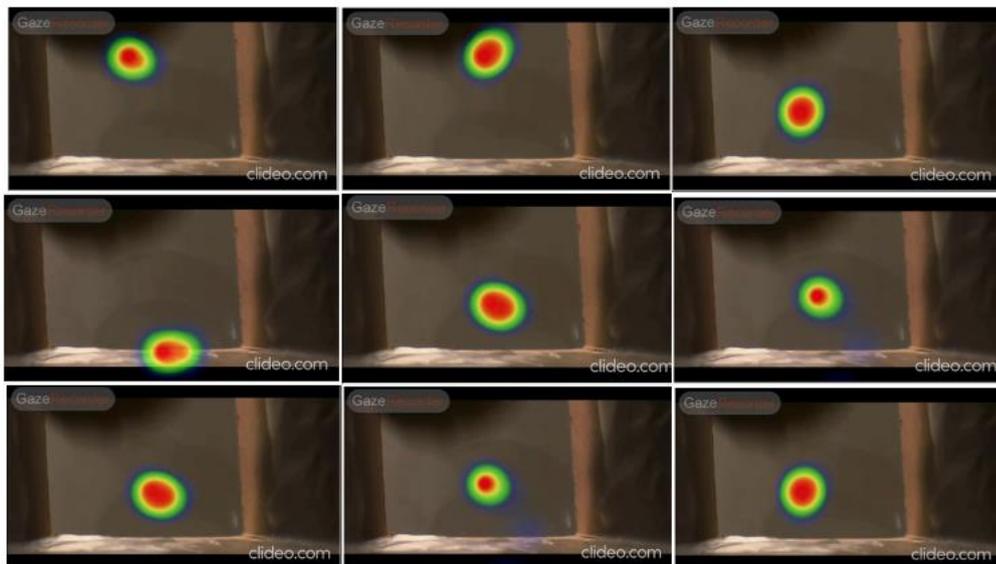
datos obtenidos. Esta selección fue respaldada por la premisa de que una muestra más reducida sería suficiente para obtener resultados preliminares que proporcionaran información relevante para futuras investigaciones en el campo del comportamiento visual.

Sin embargo, es importante reconocer las limitaciones asociadas con una muestra de este tamaño. Se reconoce que los resultados obtenidos pueden no ser completamente aplicables a poblaciones más amplias, y que las conclusiones extraídas podrían estar sujetas a una mayor incertidumbre estadística debido al tamaño limitado de la muestra. A pesar de estas consideraciones, se espera que este enfoque proporcione una base sólida para futuras investigaciones y contribuya al cuerpo de conocimiento en el área del comportamiento visual.

### 3.1.2.1. Recopilación de la información

Para recopilar información, se utiliza el sistema *Gaze Recorder* con el propósito de registrar los movimientos oculares de 20 participantes mientras visualizan el video de la marca PedidosYa. Se analizaron 750 *frames* por cada participante, lo que suma un total de 22.500 imágenes. Este análisis se lleva a cabo para identificar el punto central de cada *frame*, es decir, el área donde la mayoría de los usuarios concentra su atención.

Figura 24: Visualización de puntos de contacto



Fuente: Elaboración propia a partir de videos de contacto con Python

En la Figura 24, se presentan nueve perspectivas diferentes de un mismo *frame*, captadas desde los puntos de vista de distintos participantes. Es posible notar que no todos dirigen su mirada hacia el mismo lugar. Por esta razón, es crucial emplear metodologías que permitan identificar puntos más cercanos y posibles datos atípicos. Con el fin de sincronizar estos puntos de vista, es necesario obtener sus coordenadas y representarlas en un plano. Este proceso implica tomar los 20 puntos de vista de un cuadro y proyectarlos en un plano, generando así 750 planos en total. Esta información posteriormente se organiza en una tabla para aplicar métodos de análisis y, finalmente, obtener los puntos centrales, los cuales se consolidan en una sola columna que contiene 750 puntos. El método empleado para hacer dicha clasificación es *K-Means*.

### 3.1.2.2. *K-Means*

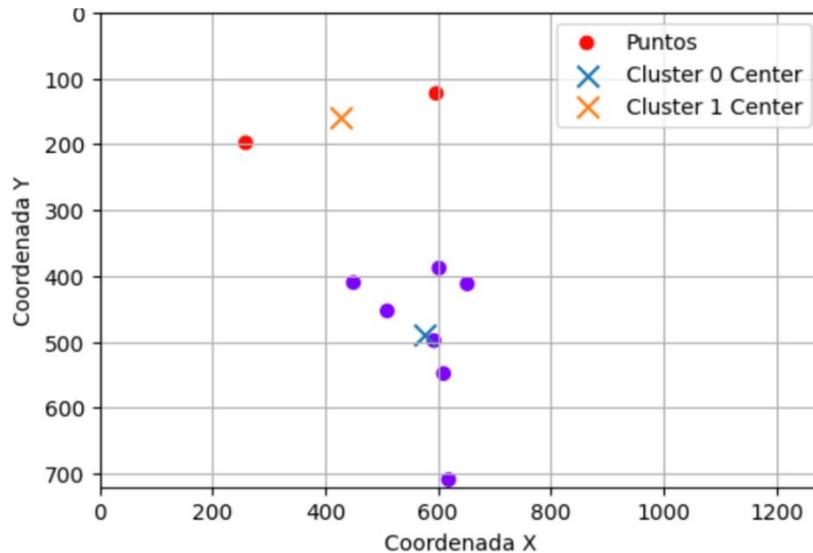
*K-Means* es un algoritmo de agrupamiento utilizado en el análisis de datos para particionar un conjunto de datos en  $K$  grupos distintos basados en características similares (Hartigan y Wong, 1979). El proceso de *K-Means* implica asignar aleatoriamente  $K$  centroides que representan los centros iniciales de los grupos y, posteriormente, asignar cada dato al grupo cuyo centroide está más cercano, utilizando una medida de distancia, como la distancia euclidiana (Lloyd, 1982):

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (25)$$

Luego, recalcula los centroides de los grupos y vuelve a asignar los datos a los grupos correspondientes de manera iterativa hasta que la asignación de datos a los grupos no cambia o se alcanza un criterio de convergencia.

El objetivo principal del algoritmo *K-Means* es minimizar la varianza intra-clúster, que representa la suma de las distancias al cuadrado entre cada punto de datos y el centroide de su grupo asignado (Hartigan y Wong, 1979). Esto implica que los puntos de datos dentro de un mismo grupo son similares entre sí y están más cerca del centroide de su grupo que de otros centroides.

Figura 25: *K-Means* aplicado a puntos de contacto- *Frame 1*



Fuente: Elaboración propia a partir de videos de contacto con Python

En la Figura 25, se ilustra un ejemplo que comprende 9 puntos. En este caso específico, se explica la asignación de valores atípicos y la determinación del valor central para aquellos puntos que no se consideran atípicos. La marca azul "X" representa el punto central elegido para el cuadro. Este procedimiento se lleva a cabo para los 750 cuadros, cada uno con sus respectivos 20 puntos asociados, generando finalmente un *Data Frame* que recopila la información proveniente de los datos no estructurados.

### 3.1.2.3. Información de los datos no estructurados

Después de aplicar los modelos de seguimiento utilizando YOLO, tanto en la detección de marcas en tiempo real como en la detección de los mapas de calores de los televidentes, se ha generado un *Data Frame* que recopila una gran cantidad de datos del video publicitario de la marca PedidosYa.

Tabla 1: Variables del modelo<sup>6</sup>

Número de Variable	Variable
x1	mo negro
x2	mo azul
x3	mo verde
x4	mo rojo
x5	microsegundos
x6	tamaño de la imagen
x7	distancia al centro
x8	clúster
x9	class
x10	centrox
x11	centroy

<sup>6</sup> Nota: Se observa las variables que contiene el Data Frame.

x12	alto
x13	ancho
x14	proba
x15	mo negro i
x16	mo azul i
x17	mo verde i
x18	mo rojo i

Fuente: Elaboración propia a partir de la información obtenida con Python.

En la tabla (1) se observan las variables a utilizar en el modelo, son 18 variables cuantitativas. Las variables independientes incluyen información como el color de los *frames*, el color de la marca, la ubicación de la marca, el tamaño y la distancia al centro. La variable dependiente es una variable dicotómica, pues es 1 cuando la distancia entre la aparición de la marca y el punto central es igual o mayor a 500 píxeles y 0 cuando es menor. Es importante resaltar que solo se tomarán los *frames* donde aparece la marca.

Identificar los factores que impiden la visibilidad de una marca permite atacar directamente las barreras específicas que limitan su reconocimiento, facilitando la implementación de cambios con un impacto significativo y medible. Este enfoque, centrado en la no efectividad, no solo prioriza acciones y recursos de manera eficiente, sino que también genera un ciclo de mejora continua y resultados tangibles.

Tabla 2: Recopilación de la información<sup>7</sup>

frameid	mo_negrot	mo_azult	mo_verdet	mo_rojot	micros	tamaño	distancia	cluster	Class
112	50	32	50	51	1	8268	110,5	1	1
113	50	32	50	51	2	8557	111,5	1	1
114	50	32	50	51	3	8505	113,0	1	1
115	50	32	50	51	4	8951	114,0	1	1

centrox	centroy	alto	ancho	proba	mo_negrot_i	mo_azult_i	mo_verdet_i	mo_rojot_i	cercanía
734	343	104	79	0,89	71	61	34	151	0
734	342	105	82	0,90	71	62	34	151	0
735	342	105	81	0,89	71	61	33	151	0
735	342	108	83	0,89	71	64	33	151	0

Fuente: Elaboración propia a partir de la información obtenida con Python.

<sup>7</sup> Nota: Se presenta una sección específica del *Data Frame* que incluye únicamente los *frames* en los que aparece la marca.

Esta representación resalta cómo un solo video puede proporcionar una gran cantidad de información. Con estos datos recopilados, se cuenta con los elementos necesarios para proceder con la creación del modelo. Es importante resaltar que el modelo es de clasificación pues la variable respuesta es dicotómica.

### 3.2. Modelos de clasificación para optimizar la visualización de la marca

Un modelo de clasificación en aprendizaje automático es una representación matemática en un algoritmo que se utiliza para "predecir la pertenencia de una muestra de datos a una o más categorías o clases discretas" (James *et al.*, 2013, p. 9). Estos modelos son entrenados utilizando conjuntos de datos históricos que poseen características conocidas y etiquetas de clase asociadas, con el propósito de "predecir la clase a la que pertenecerán nuevas muestras basadas en sus características" (Bishop, 2006, p. 3).

El objetivo primordial de un modelo de clasificación radica en "asignar una etiqueta de clase a una instancia desconocida basándose en la información aprendida durante el entrenamiento" (James *et al.*, 2013, p. 9). Estos modelos pueden utilizar diversos algoritmos y técnicas, como regresión logística, árboles de decisión, máquinas de vectores de soporte (SVM), redes neuronales, entre otros, para llevar a cabo esta tarea de clasificación. Estos modelos "aprenden patrones y relaciones complejas entre las características de entrada y las etiquetas de clase conocidas para realizar predicciones precisas sobre nuevas muestras de datos" (Bishop, 2006, p. 3). La evaluación de la calidad de estos modelos se lleva a cabo utilizando métricas como la precisión, sensibilidad, especificidad y el área bajo la curva ROC, permitiendo medir su rendimiento en la predicción de las clases.

El conjunto de datos (*Data Frame*) con el que se va a trabajar tiene 167 filas, que representan los píxeles donde apareció la marca y cuenta con 30 columnas, donde la columna final son 0 y 1, específicamente 127 ceros y 39 unos. Con la intención de clasificar de manera óptima se divide el *Data Frame* en dos subconjuntos, Train y Test:

Tabla 3: Variable dependiente<sup>8</sup>

TRAIN		TEST	
Distancia menor o igual a 500 píxeles	89	Distancia menor o igual a 500 píxeles	38

<sup>8</sup> Nota: Se aprecia la división efectuada y la disposición de la información de prueba.

Fuente: Elaboración propia a partir de la información obtenida con Python.

Posteriormente, se procede a la aplicación de los modelos, evaluando su rendimiento en función de su capacidad para aproximarse a los valores reales. Dicha aproximación se mide teniendo en cuenta la matriz de confusión.

La matriz de confusión es una herramienta para la evaluación de modelos de clasificación en aprendizaje automático. Proporciona un resumen de la calidad de las predicciones realizadas por un modelo comparando las predicciones con las etiquetas reales de los datos. Esta se organiza en filas y columnas, donde cada fila representa las clases reales y cada columna representa las clases predichas por el modelo (Visa *et al.*, 2011). En su forma más básica, una matriz de confusión para un problema de clasificación binaria tiene la siguiente estructura:

Figura 26: Matriz de confusión

	Predicción negativa	Predicción positiva
Negativo	Verdadero Negativo(TN)	Falso Positivo(FP)
Positivo	Falso Negativo(FN)	Verdadero Positivo(TP)

Fuente: Elaboración propia

En la Figura 26 se muestra una matriz de confusión. En ella, se distinguen cuatro elementos clave: Verdadero Positivo (TP), Verdadero Negativo (TN), Falso Positivo (FP) y Falso Negativo (FN). Los verdaderos positivos son las muestras correctamente identificadas como positivas, los verdaderos negativos son las muestras correctamente identificadas como negativas, los falsos positivos son las muestras incorrectamente identificadas como positivas (error tipo I) y los falsos negativos son las muestras incorrectamente identificadas como negativas (error tipo II).

Esta matriz se usará para identificar la eficiencia de los modelos de manera gráfica. Existen diversas métricas para evaluar un modelo de clasificación (Visa *et al.*, 2011). Por un lado, la precisión indica la proporción de muestras relevantes o positivas predichas por el modelo que son positivas de verdad:

$$\text{Precisión} = \frac{TP}{TP+FP} \quad (26)$$

Por otro lado, el *recall* indica la proporción de muestras relevantes o positivas predichas por el modelo respecto a todas las muestras que son positivas:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (27)$$

Otra manera de evaluar un modelo es con las métricas de sensibilidad y especificidad. La sensibilidad indica lo bien que se ha predicho la clase positiva y es equivalente al recall:

$$\text{Sensibilidad} = \frac{TP}{TP+FN} \quad (28)$$

La especificidad es la métrica complementaria e indica lo bien que se ha clasificado la clase negativa:

$$\text{Especificidad} = \frac{TN}{FP+TN} \quad (29)$$

Finalmente, la medida que se usa para validar el rendimiento total del modelo es la Accuracy, en un modelo de clasificación es una medida que indica la proporción de predicciones correctas realizadas por el modelo sobre el total de predicciones realizadas.

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (30)$$

Después de tener claridad en las métricas a utilizar se procede a realizar la predicción utilizando los diversos modelos de detección.

### 3.2.1. KNN

El algoritmo *KNN* (*K-Nearest Neighbors*) es un método de clasificación utilizado en aprendizaje supervisado, que predice la pertenencia de una muestra de datos a una o más categorías basándose en la proximidad a otros ejemplos etiquetados. Se considera como "un algoritmo simple y efectivo de clasificación" (Hastie *et al.*, 2009, p. 481).

Figura 27: Notación para el clasificador *KNN*

		$X_1$	...	$X_j$	...	$X_n$	$C$
$(\mathbf{x}_1, c_1)$	1	$x_{11}$	...	$x_{1j}$	...	$x_{1n}$	$c_1$
	$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$(\mathbf{x}_i, c_i)$	$i$	$x_{i1}$	...	$x_{ij}$	...	$x_{in}$	$c_i$
	$\vdots$	$\vdots$		$\vdots$		$\vdots$	$\vdots$
$(\mathbf{x}_N, c_N)$	$N$	$x_{N1}$	...	$x_{Nj}$	...	$x_{Nn}$	$c_N$
$\mathbf{x}$	$N + 1$	$x_{N+1,1}$	...	$x_{N+1,j}$	...	$x_{N+1,n}$	?

Fuente: imagen tomada de Tema 5. Clasificadores *KNN* Abdelmalik Moujahid (1997).

En la imagen 27,  $D$  indica un fichero de  $N$  casos, cada uno de los cuales está caracterizado por  $n$  variables predictoras,  $X_1, \dots, X_n$  y una variable a predecir, la clase  $C$ . Los  $N$  casos se denotan por  $(x, c_1), \dots, (x_N, c_N)$ , donde  $x_i = (x_{i,1}, \dots, x_{i,n})$  para todo  $i = 1, \dots, N$  y  $c_i \in \{c^1, \dots, c^m\}$  para todo  $i = 1, \dots, N$ .  $c^1, \dots, c^m$  denotan los  $m$  posibles valores de la variable clase  $C$ . El nuevo caso que se pretende clasificar se denota por  $x = (x_1, \dots, x_n)$ .

Con el fin de explicar el algoritmo a continuación se realiza una representación de los pasos de forma matemática y de forma gráfica:

Figura 28: Pseudocódigo para el clasificador *KNN*

COMIENZO

Entrada:  $D = \{(x_1, c_1), \dots, (x_N, c_N)\}$

$x = (x_1, \dots, x_n)$  nuevo caso a clasificar

PARA todo objeto ya clasificado  $(x_i, c_i)$

calcular  $d_i = d(x_i, x)$

Ordenar  $d_i (i = 1, \dots, N)$  en orden ascendente

Quedarnos con los  $K$  casos  $D_x^K$  ya clasificados más cercanos a  $x$

Asignar a  $x$  la clase más frecuente en  $D_x^K$

FIN

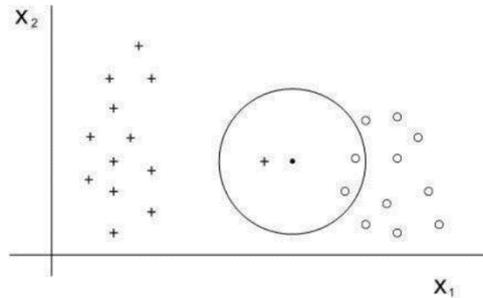
Fuente: imagen tomada de Tema 5. Clasificadores *KNN* Abdelmalik Moujahid (1997).

La figura 28 presenta un pseudocódigo. El proceso comienza con un conjunto de datos de entrenamiento que contiene ejemplos previamente etiquetados. Cuando se presenta un nuevo ejemplo (llamado caso  $x$ ) que necesita ser clasificado, el algoritmo calcula la distancia entre este caso y todos los casos de entrenamiento.

En el pseudocódigo proporcionado, la primera parte del algoritmo consiste en calcular las distancias entre el caso  $x$  y todos los casos ya clasificados. Esto implica calcular la distancia entre el caso  $x$  y cada uno de los casos en el conjunto de entrenamiento. Luego, el algoritmo selecciona los  $k$  casos más cercanos (llamados vecinos más cercanos) al caso  $x$ . Estos  $k$  vecinos se eligen basándose en las distancias previamente calculadas (Moujahid *et al.*, 2019). El valor de  $k$  es un parámetro que se puede ajustar y representa el número de vecinos más cercanos que se tomarán en cuenta para la clasificación. Finalmente, una vez que se han seleccionado los  $k$  vecinos más cercanos, el algoritmo asigna al caso  $x$  la

clase más frecuente entre estos vecinos. En otras palabras, el caso  $x$  se clasifica como perteneciente a la clase que es más común entre sus  $k$  vecinos más cercanos (Moujahid et al., 2019).

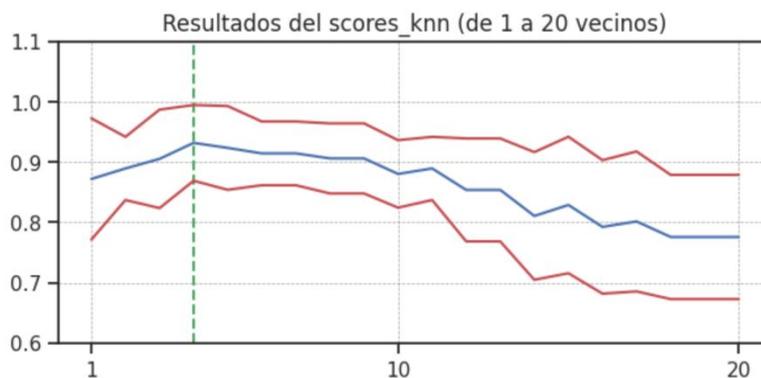
Figura 29: Ejemplo de aplicación del algoritmo  $KNN$



Fuente: imagen tomada de Tema 5. Clasificadores  $KNN$  Abdelmalik Moujahid(1997).

La Figura 29 muestra de manera gráfica lo explicado en el pseudocódigo. En este caso en particular, se clasifica en 2 valores. Las variables predictoras son  $X_1$  y  $X_2$ , y se ha seleccionado  $K = 3$ . El valor de  $K$  representa el número de vecinos considerados. Un  $K$  más pequeño puede generar modelos más complejos y propensos al sobreajuste, mientras que un  $K$  mayor puede suavizar las fronteras de decisión, aunque con una posible reducción de precisión.

Figura 30: Curva de validación del Score  $KNN$

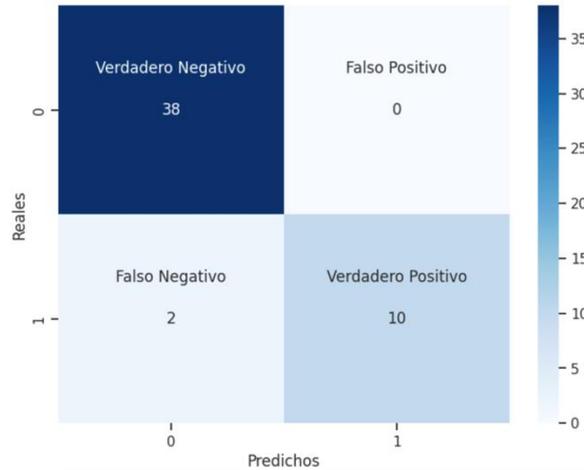


Fuente: Elaboración propia a partir del modelo  $KNN$  en Python.

En la Figura 30 se presenta el resultado de aplicar la curva de validación mediante *Cross Validation* del modelo de  $KNN$  a los datos, el eje Y representa el rendimiento y el eje X representa  $k$ . Esta curva representa cómo cambia el rendimiento del modelo medido por la precisión, el pico indica que el modelo alcanza su mejor rendimiento con  $k=4$  porque

en este valor, el modelo logra un equilibrio óptimo entre el sesgo y la varianza. Posteriormente, se genera la matriz de confusión utilizando este valor óptimo.

Figura 31: Matriz de confusión de *KNN*



Fuente: Elaboración propia a partir del modelo *KNN* en Python.

En la Figura 31, se presenta la matriz de confusión generada al aplicar el algoritmo *KNN*. Esta matriz ofrece una visión detallada del rendimiento del modelo en la clasificación de las muestras. Se observa que el modelo tiene un desempeño óptimo, ya que solo se registran dos casos de falsos negativos. Tiene un *Accuracy* de  $0.96 = \left(\frac{38+10}{38+10+2}\right)$ , una sensibilidad de  $0.83 = \left(\frac{10}{10+2}\right)$  y una especificidad de  $1 = \left(\frac{38}{38+0}\right)$ . Esto indica que el modelo ha clasificado correctamente la mayoría de las muestras positivas, con un bajo número de casos en los que erróneamente clasificó una muestra positiva como negativa.

### 3.2.2. *Decision Tree*

Los árboles de decisión (*Decision tree*) son una técnica de aprendizaje automático utilizada en problemas de clasificación y regresión. Son modelos predictivos que se asemejan a estructuras de árboles y se utilizan para tomar decisiones al dividir un conjunto de datos en subconjuntos más pequeños y manejables. Se caracterizan por su naturaleza intuitiva y fácil interpretación (Breiman *et al.*, 1984).

En cada paso, el algoritmo selecciona la característica que mejor separa las clases en el conjunto de datos. Esto se hace mediante la maximización de una métrica de impureza como la ganancia de información o la impureza de Gini (Breiman *et al.*, 1984). Esta viene dada por:

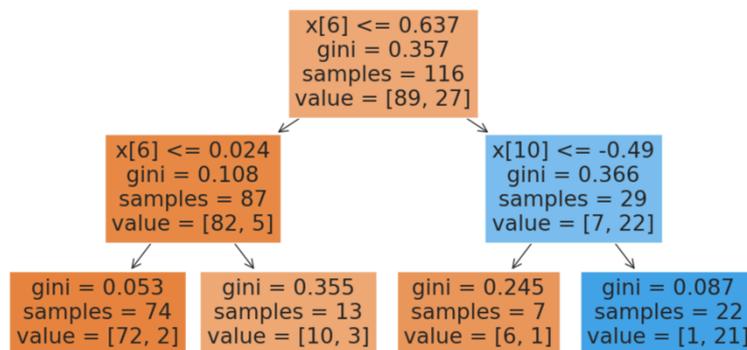
$$Gain(S, A) = Impurity(S) - \sum_{v \in values(A)} \frac{|S_v|}{|S|} \cdot Impurity(S_v) \quad (31)$$

donde  $S$  es el conjunto de datos,  $A$  es una característica,  $S_v$  es el subconjunto de  $S$  donde la característica  $A$  tiene el valor  $v$ ,  $Impurity(S)$  es una medida de impureza en el conjunto  $S$ , y  $values(A)$  son los valores posibles de la característica  $A$ .

Una vez seleccionada la característica, el conjunto de datos se divide en subconjuntos basados en los valores de esa característica. Este proceso se repite recursivamente en cada uno de los subconjuntos resultantes hasta que se cumple un criterio de parada, como alcanzar una profundidad máxima, tener un número mínimo de muestras en un nodo hoja, o si no se puede mejorar la pureza de la división (Larrañaga *et al.*, 1997). El árbol de decisión crece hasta que se cumple un criterio de parada, como los mencionados anteriormente. Después de que se construye el árbol, se puede aplicar un proceso de podado para evitar el sobreajuste, eliminando subárboles que no contribuyen significativamente a la precisión del modelo (Larrañaga *et al.*, 1997).

En un árbol de decisión, cada nodo interno representa una característica del conjunto de datos, cada rama representa una regla de decisión y cada hoja representa el resultado de una clasificación o predicción (Breiman *et al.*, 1984). Los árboles de decisión son flexibles y pueden manejar datos numéricos y categóricos, además de ser resistentes a valores atípicos. Sin embargo, pueden ser propensos al sobreajuste si no se controla su complejidad mediante técnicas como la poda o la limitación de la profundidad del árbol.

Figura 32: *Decision Tree*

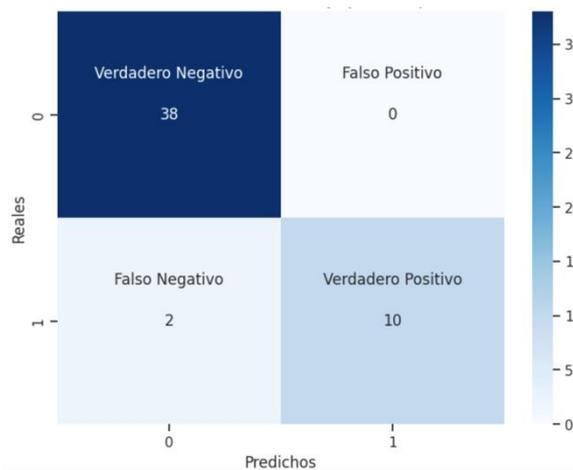


Fuente: Elaboración propia a partir de *Decision Tree* obtenido en Python.

En la Figura 32, se presenta el *Decision Tree* derivado del análisis de los datos del video de la Marca PedidosYa. Se Utilizó *GridSearchCV* para probar cada profundidad

especificada y realizar una validación cruzada con 5 pliegues. Esto ayuda a encontrar la mejor profundidad basada en el rendimiento promedio, siendo esta profundidad de 2. En este diagrama, se destaca que el tamaño de la marca (variable 6) constituye el primer nodo de clasificación. A continuación, se considera el centro x de la detección de la marca (variable 10). Es notable cómo la clasificación varía en función de los valores de estas variables, lo que indica la importancia relativa de cada una en la determinación de la clase de la marca detectada.

Figura 33: Matriz de confusión de *Decision Tree*



Fuente: Elaboración propia a partir de *Decision Tree* obtenido en Python.

En la Figura 33, se presenta la matriz de confusión generada por el *Decision Tree*. Es notable que el modelo demuestra un rendimiento óptimo, ya que solo produce 2 falsos negativos. Tiene un *Accuracy* de  $0.96 = \left(\frac{38+10}{38+10+2}\right)$ , una sensibilidad de  $0.83 = \left(\frac{10}{10+2}\right)$  y una especificidad de  $1 = \left(\frac{38}{38+0}\right)$ . Este resultado coincide con el modelo anterior, lo que sugiere una consistencia en las predicciones que es probable que persista en otros modelos. Se anticipa que las disparidades entre los modelos sean mínimas debido a la limitada cantidad de datos disponibles para el análisis.

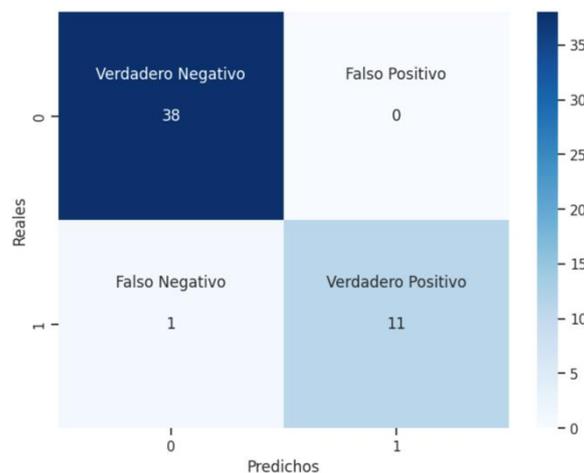
### 3.2.3. *Random Forest*

*Random Forest* es un algoritmo de aprendizaje automático que se basa en la construcción de múltiples árboles de decisión y su combinación para realizar predicciones (Breiman, 2001). Este método pertenece a la familia de los métodos de ensamble y se destaca por su eficacia en la reducción del sobreajuste y en la mejora de la precisión predictiva en comparación con un solo *Decision Tree*.

En *Random Forest*, se generan múltiples *Decision Trees* de forma independiente utilizando diferentes subconjuntos aleatorios de características y datos de entrenamiento. Cada *Decision Tree* se entrena con un subconjunto de datos y características, y posteriormente realiza predicciones. Luego, para obtener la predicción final, se promedian las predicciones de todos los árboles en el caso de la regresión o se toma la moda en el caso de la clasificación (Breiman, 2001).

Este enfoque de "bosque" o conjunto de árboles aleatorios permite reducir la varianza y mejorar la generalización del modelo, ya que cada árbol se entrena de manera independiente y la combinación de múltiples árboles ayuda a evitar el sobreajuste. *Random Forest* es robusto frente a datos ruidosos y valores atípicos, y puede manejar grandes conjuntos de datos con muchas características (Breiman, 2001).

Figura 34: Matriz de confusión de *Random Forest*



Fuente: Elaboración propia a partir del modelo *Random Forest* en Python.

En la Figura 34, se exhibe la matriz de confusión generada por el *Random Forest*. Para elegir los hiperparámetros óptimos de un modelo *Random Forest*, incluyendo la profundidad de los árboles en cada estimador del bosque, se sigue un proceso similar al utilizado para un solo árbol de decisión, pero adaptado al contexto de *Random Forest*. Se utilizó *RandomForestClassifier* y *GridSearchCV* para encontrar la combinación óptima de hiperparámetros.

Los hiperparámetros óptimos para el modelo *Random Forest* fueron los siguientes: la profundidad máxima de los árboles individuales (*max\_depth*) se configuró en *None*, lo que indica que no hay restricción en la profundidad de los árboles. El número máximo de características consideradas en cada división de nodo (*max\_features*) se estableció en

Auto, lo que significa que se consideran todas las características ( $\sqrt{n\_features}$ ) en clasificación). El número mínimo de muestras requeridas para que un nodo sea una hoja ( $min\_samples\_leaf$ ) fue configurado en 4 muestras. El número mínimo de muestras requeridas para dividir un nodo interno ( $min\_samples\_split$ ) se estableció en 10 muestras. Además, se emplearon 100 árboles en el *Random Forest* ( $n\_estimators$ )

Como se señaló anteriormente, hay consistencia en las predicciones, atribuible a las mínimas disparidades entre los modelos debido a la cantidad de datos limitada para el análisis. Sin embargo, se observa una mejora en la matriz en comparación con el árbol de decisión, con solo un falso negativo. Tiene un *Accuracy* de  $0.98 = \left(\frac{38+11}{38+11+1}\right)$ , una sensibilidad de  $0.92 = \left(\frac{11}{11+1}\right)$  y una especificidad de  $1 = \left(\frac{38}{38+0}\right)$ . Este resultado es coherente, dado que el *Random Forest* representa una mejora con respecto al árbol de decisión.

### 3.2.4. Regresión logística

La regresión logística es un método utilizado en el análisis estadístico y el aprendizaje automático para modelar la relación entre una variable dependiente categórica y variables independientes. Es principalmente utilizado en tareas de clasificación (Hosmer *et al.*, 2013).

La regresión logística modela la probabilidad de que una instancia pertenezca a una clase particular. Utiliza una función logística (también conocida como función sigmoide) para transformar la salida del modelo a un valor entre 0 y 1, que puede interpretarse como la probabilidad de pertenecer a la clase positiva. La función logística se define como:

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (32)$$

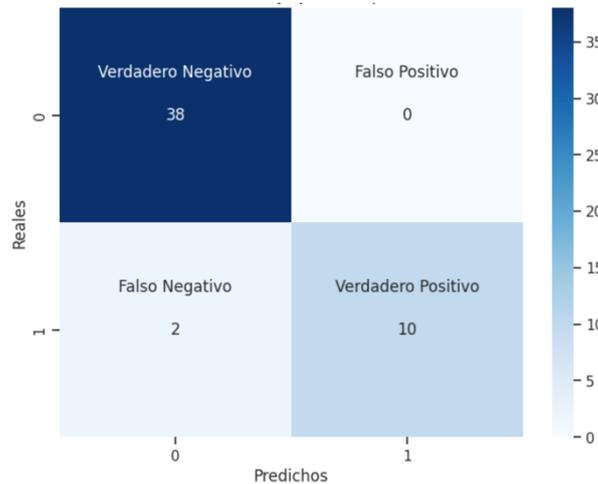
donde  $z$  es la entrada del modelo, que es una combinación lineal de las características y los parámetros del modelo:

$$z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (33)$$

Aquí  $x_1, x_2, \dots, x_n$  son las características de la instancia y  $\beta_0, \beta_1, \dots, \beta_n$  son los parámetros del modelo, cuyos coeficientes estimados representan la contribución

relativa de cada variable independiente en la predicción de la variable dependiente categórica. El modelo busca maximizar la verosimilitud de los datos observados para ajustar estos coeficientes (Hosmer Jr *et al.*, 2013).

Figura 35: Matriz de confusión con Regresión Logística con validación cruzada



Fuente: Elaboración propia a partir del modelo de Regresión Logística en Python.

En la Figura 35 se presenta la matriz de confusión generada a partir de la aplicación del modelo de regresión logística. Para ajustar los hiperparámetros de este modelo en primero y encontrar la configuración óptima se probó validación cruzada. Destaca la notable similitud de los resultados con los obtenidos mediante el empleo de los modelos KNN y árbol de decisión. Tiene un *Accuracy* de  $0.96 = \left(\frac{38+10}{38+10+2}\right)$ , una sensibilidad de  $0.83 = \left(\frac{10}{10+2}\right)$  y una especificidad de  $1 = \left(\frac{38}{38+0}\right)$ . Esta congruencia entre los resultados de los distintos modelos resalta la consistencia y fiabilidad de las predicciones realizadas.

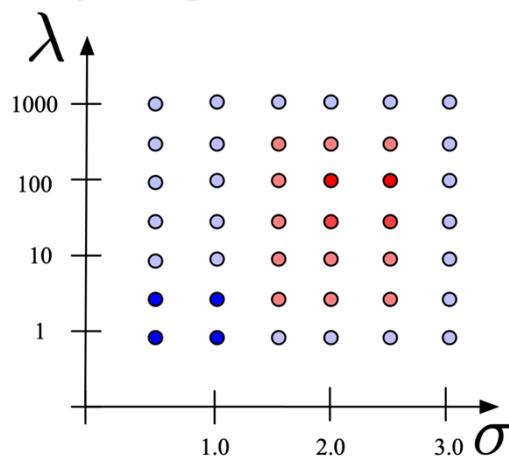
### 3.2.5. Regresión Logística con *Grid Search*

La regresión logística con *Grid Search* es una técnica que combina la regresión logística con el método de búsqueda en cuadrícula (*Grid Search*) para encontrar los mejores hiperparámetros que optimizan el rendimiento del modelo. Esta fue propuesta por Lerman en 1980 en el artículo *Fitting Segmented Regression Models by Grid Search*.

El método *Grid Search* se utiliza para la mejor combinación de hiperparámetros para un modelo de aprendizaje automático. Estos hiperparámetros son variables que controlan el comportamiento del modelo, como la tasa de aprendizaje en la regresión logística o el número de vecinos en un *K-Nearest Neighbors*. En este modelo primero se seleccionan

los hiperparámetros que se quieren optimizar. Después se define un conjunto de valores posibles para cada hiperparámetro. La combinación de estos valores forma una "cuadrícula" de posibles configuraciones del modelo. Se entrena el modelo con cada combinación de valores de la cuadrícula. Para evitar el sobreajuste, se utiliza la técnica de validación cruzada para evaluar el rendimiento de cada configuración. Finalmente se selecciona la configuración que produce el mejor rendimiento en la validación cruzada. Esta configuración se considera la mejor combinación de hiperparámetros para el modelo (Lerman,1980).

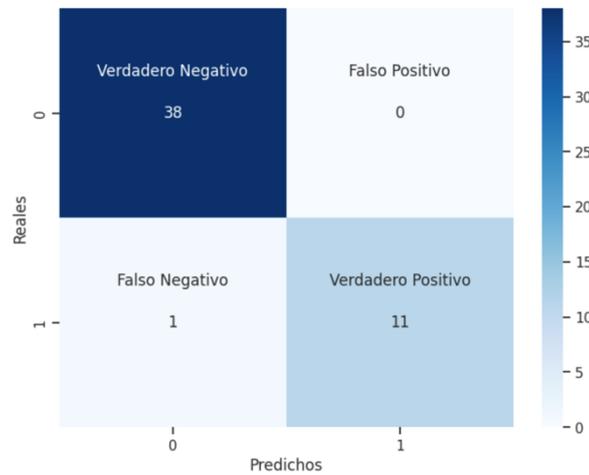
Figura 36: proceso de *Grid Search*



Fuente: Elaboración propia, tomado como referencia explicación de Feurer y Hutter, 2019

La Figura 36 ilustra el proceso de *GridSearch*. En el eje X se muestran los valores del hiperparámetro 1 y en el eje Y los valores del hiperparámetro 2. Cada punto de la cuadrícula representa una combinación de valores de los dos hiperparámetros. El color de cada punto indica el rendimiento del modelo para esa configuración, con colores más cálidos que indican un mejor rendimiento. La configuración con el mejor rendimiento (color más cálido) se selecciona como la mejor combinación de hiperparámetros.

Figura 37: Matriz de confusión con Regresión Logística con *GridSearch*



Fuente: Elaboración propia a partir del modelo de Regresión Logística con *Grid Search* en Python

En la Figura 37 exhibe la matriz de confusión resultante de la aplicación de la Regresión Logística mediante el método de *Grid Search*. De manera destacada, se observa una mejora significativa con respecto a la matriz generada por la regresión logística estándar, lo cual resalta la eficacia de la optimización realizada. Además, se destaca la equiparable eficacia de esta mejora en comparación con el modelo *Random Forest*. Tiene un *Accuracy* de  $0.98 = \left(\frac{38+11}{38+11+1}\right)$ , una sensibilidad de  $0.92 = \left(\frac{11}{11+1}\right)$  y una especificidad de  $1 = \left(\frac{38}{38+0}\right)$ . Este hallazgo subraya la capacidad de la Regresión Logística con *Grid Search* para generar resultados competitivos y confiables, evidenciando su robustez y relevancia en el contexto del análisis predictivo.

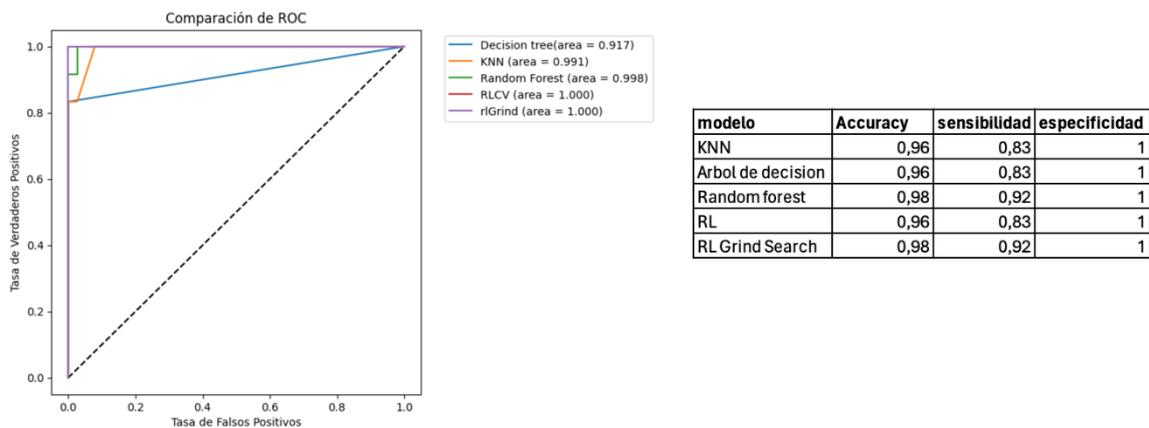
### 3.3. Selección del mejor modelo y resultados del proceso de detección

La selección del mejor modelo en el proceso de detección es un aspecto crucial que influye directamente en la efectividad y precisión de los resultados obtenidos. Este proceso implica la evaluación meticulosa de una variedad de modelos estadísticos, cada uno con sus propias ventajas y limitaciones. Para llevar a cabo esta evaluación de manera efectiva, se recurre a técnicas como la validación cruzada y se emplean métricas de rendimiento como la precisión, la sensibilidad y la especificidad, definidas en el apartado 3.2. Además, se consideran aspectos prácticos como la interpretabilidad del modelo y su escalabilidad computacional, garantizando su aplicabilidad.

### 3.3.1 Selección del modelo

Al profundizar en la selección del modelo se detallan los resultados del proceso de detección. En este análisis exhaustivo se evaluaron cinco modelos distintos: *k-Nearest Neighbors (KNN)*, *Árbol de Decisión*, *Random Forest*, *Regresión Logística* y *Regresión Logística con GridSearch*. Utilizando matrices de confusión, se comparó el desempeño de cada modelo en la tarea específica de detección.

Figura 38: Comparación de modelos



Fuente: Elaboración propia a partir de los modelos con Python

La Figura 38 presenta una visualización detallada de los resultados obtenidos tras la evaluación de todos los modelos analizados. Destaca una especificidad del 100% en cada modelo, resaltando así la precisa predicción de distancias cercanas. En términos de sensibilidad, se destaca que tanto Random Forest como Regresión Logística con *GridSearch* exhibieron una sensibilidad superior, superando el umbral del 90%. Además, estos modelos lograron un Accuracy del 98%, superando el 96% alcanzado por los otros tres modelos evaluados.

Es importante tener en cuenta que estos resultados están limitados debido a la pequeña cantidad de datos de prueba utilizados, que consta de solo 50 observaciones. Por lo tanto, sería beneficioso aplicar este procedimiento a un conjunto de datos más extenso, posiblemente obtenido de un video más largo, para recopilar más información y entrenar el modelo con una cantidad de datos más significativa. A pesar de estas limitaciones, estos modelos han demostrado ser capaces de identificar correctamente los casos positivos, o en este caso particular, identificar cuando las marcas están más cercanas al punto central, lo que los posiciona como opciones destacadas para aplicaciones donde la detección precisa es crucial.

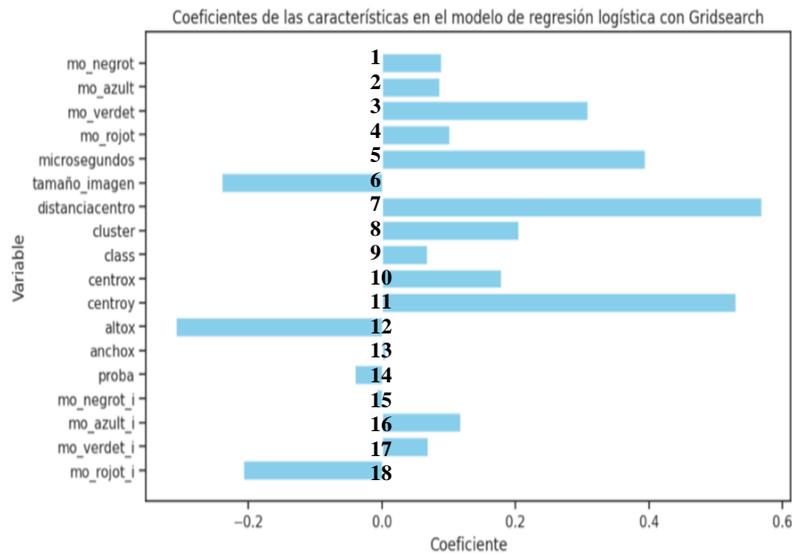
Entre *Random Forest* y Regresión Logística con *GridSearch*, esta última ofrece una mejor interpretabilidad y escalabilidad computacional. La Regresión Logística, al ser lineal, resulta más fácil de interpretar. Sus coeficientes estimados brindan detalles sobre la dirección y la magnitud de la relación entre las variables independientes y la variable dependiente, lo que facilita la comprensión de cómo cada variable influye en las predicciones.

Además, la Regresión Logística tiende a ser más escalable en términos de recursos computacionales en comparación con *Random Forest*. Aunque los modelos de *Random Forest* pueden ser altamente precisos y robustos contra el sobreajuste, su interpretación suele ser más compleja debido a la combinación de múltiples árboles de decisión. Además, el proceso de entrenamiento de *Random Forest* puede ser más demandante computacionalmente, especialmente con conjuntos de datos extensos, sin embargo, no es el caso ya que en el presente estudio tiene un conjunto de datos reducidos.

La escasez de datos en este estudio se justifica por la búsqueda de una aplicación específica con potencial para generalizarse en el futuro. Esta elección permitió explorar detalladamente el comportamiento de los modelos en condiciones de baja cantidad de datos, una consideración crucial para su aplicación práctica en escenarios del mundo real.

En este contexto, se ha tomado la decisión de emplear el modelo de Regresión Logística con *GridSearch* como la herramienta principal para el análisis. A partir de esta elección, se procede a profundizar en la exploración de los coeficientes generados por dicho modelo. Esta etapa es crucial, ya que permite desentrañar los factores y variables que más influyen en las predicciones del modelo, proporcionando así un mayor entendimiento del proceso de clasificación y su aplicación en el contexto específico de estudio.

Figura 39: Coeficientes característicos del mejor modelo



Fuente: Elaboración propia a partir de Regresión Logística con *GridSearch* en Python

La Figura 39 ofrece una exploración detallada de los coeficientes característicos del modelo de regresión logística con *GridSearch*. Este análisis revela varios aspectos importantes que influyen en la probabilidad de visualización de una imagen. En primer lugar, destaca la variable número 7 que es la distancia al centro, donde se observa que cuanto más cercana está la imagen al centro de la pantalla, mayor es la probabilidad de que sea visualizada. Además, la variable número 11 (la cercanía al eje y, es decir, al centro vertical) muestra que también aumenta la probabilidad de visualización de la imagen.

Otro factor significativo es la variable número 5 que es el tiempo en pantalla, donde se evidencia que, a mayor tiempo de exposición, mayor probabilidad de visualización. Sin embargo, se observa una tendencia interesante. Si la variable 12, altura de la imagen y la variable 6, tamaño de la imagen son muy grandes, la distancia entre el punto central y la marca tiende a ser mayor. Este hallazgo sugiere que existe un punto óptimo en cuanto al tamaño y proporción de la imagen para maximizar su visualización. Además, se destaca que la variable 18, la presencia de tonos rojos en la imagen, ~~esta~~ puede influir en la probabilidad de visualización. En este caso particular, se observa que una alta presencia de rojo puede disminuir la probabilidad de que la imagen sea vista. Este hallazgo resalta la importancia del color y su impacto en la atención visual.

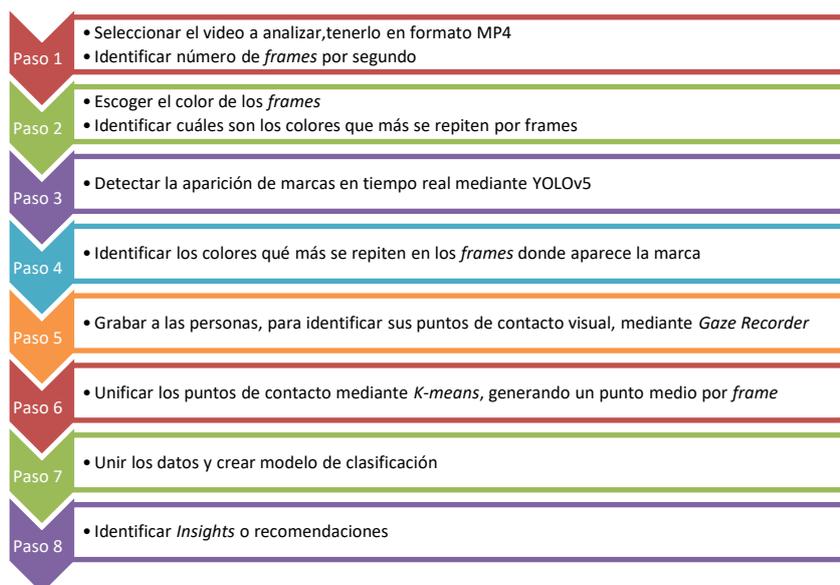
Es esencial considerar que este modelo se aplica de manera específica a las marcas y a un anuncio publicitario concreto. Es imperativo realizar un análisis individualizado para cada video con el propósito de extraer *insights* específicos y relevantes para esa campaña

en particular. Sin embargo, el proceso de aplicación del modelo y la metodología utilizada tienen la capacidad de ser extrapolados a otros contextos y campañas publicitarias. Siguiendo siempre los mismos pasos, a continuación, se realiza una demostración.

### 3.3.2 Proceso de detección

El proceso de detección, a pesar de esperar resultados variados según el contenido y las características de cada anuncio, sigue una metodología subyacente consistente. Esta uniformidad en el enfoque garantiza la replicabilidad y la aplicabilidad del modelo en diferentes escenarios publicitarios. Por lo tanto, aunque los insights y las conclusiones pueden diferir entre distintas campañas, la estructura y el enfoque metodológico permanecen constantes, lo que facilita la adaptación y la implementación del modelo en diversos contextos publicitarios con confianza y eficacia.

Figura 40: proceso de detección



Fuente: Elaboración propia.

La Figura 40 ofrece una detallada explicación del proceso integral realizado para comprender los aspectos que contribuyen a la visibilidad de una marca entre los televidentes. Este proceso se organiza en ocho pasos secuenciales. En primer lugar, se inicia con la selección del video a analizar, seguido por la identificación del número de *frames* por segundo. Posteriormente, se procede a la selección del color de los *frames*, identificando los colores más recurrentes. Luego, se lleva a cabo la detección de la aparición de marcas utilizando la herramienta YOLOv5. A continuación, se identifican

los colores que predominan en cada marca. Seguidamente, se registran los puntos de contacto de las personas con la marca. A partir de estos puntos, se genera el punto medio, unificando así los datos recopilados.

Es importante resaltar que los últimos pasos del proceso, la generación del modelo y el análisis final, presentan variaciones dependiendo del video analizado. En esta fase, se exploran distintos modelos para determinar el más idóneo y se derivan recomendaciones pertinentes, considerando los coeficientes obtenidos del modelo. Es decir, la adaptación del proceso de detección es fundamental en cada video evaluado.

Este proceso de detección, aunque varíe para cada video, resulta fundamental para las marcas que invierten en *Product Placement*. Cuando una marca realiza esta inversión, es necesario verificar que el tiempo de aparición pagado corresponda efectivamente con la exposición recibida. El método propuesto automatiza esta verificación, ofreciendo una auditoría *frame a frame* fiable. En particular, en el caso de *Product Placement* en *realities*, donde la marca está en constante exposición, contar con datos precisos puede potenciar su presencia y optimizar la visualización de la marca, ya que garantiza que la marca aparezca durante más tiempo del que pagó inicialmente.

Para comprender cómo se factura por el tiempo en pantalla, es relevante hablar sobre los TRPs. Tradicionalmente, el costo que una marca paga por aparecer en un programa se basa en el número esperado de TRPs que la aparición generará, junto con otros factores como la popularidad del programa y el presupuesto de la marca (Singh *et al.*, 2011). Esta estimación de TRPs influye en la negociación del precio, que puede expresarse como un costo por cada 1,000 TRPs (CPM) o como un costo total por la duración del contrato de aparición. Durante la emisión, se realiza un seguimiento de los TRPs reales, y cualquier desviación significativa puede resultar en ajustes en el precio acordado según lo establecido en el contrato (Singh *et al.*, 2011).

Al mejorar el proceso de evaluación de la efectividad del *Product Placement* mediante técnicas de procesamiento avanzadas, se puede enriquecer la información utilizada para calcular los TRPs. Esto, a su vez, tiene un impacto directo en la optimización de la visualización para las marcas que invierten en publicidad televisiva, especialmente en contextos como *Realities* donde el *Product Placement* es frecuente. Para ilustrar este punto, se considera un ejemplo hipotético basado en datos reales de un programa de

*Reality* donde una marca pagó inicialmente \$143,550 por su presencia. Mediante el enfoque tradicional de cálculo de TRP, este valor representa el costo del tiempo de exposición estimado según las mediciones estándar.

Sin embargo, al emplear el método mejorado de procesamiento que permite una auditoría más precisa *frame a frame*, se descubre que la marca tuvo una exposición real que equivaldría a un costo de \$189,310 si se facturara por cada instancia de aparición. Este análisis revela que, al optimizar el cálculo del TRP mediante un proceso mejorado de determinación de la exposición real, la marca en cuestión habría obtenido un retorno de inversión un 31.87% mayor en términos de exposición televisiva, generando una optimización en la visualización de la marca. Esta mejora en la precisión del cálculo del TRP permite a las marcas tomar decisiones más informadas sobre su inversión en *Product Placement*, maximizando así la visualización de la marca, lo que a su vez genera una maximización en el retorno de su inversión publicitaria y optimiza la inversión global.

En este contexto, las marcas tienen la oportunidad de capitalizar los datos obtenidos sobre la exposición y el potencial del *Product Placement* para negociar acuerdos más favorables con los productores de contenido o los organizadores de eventos. Este enfoque implica obtener una mayor visibilidad para el producto, ya sea integrándolo en momentos estratégicos del contenido o negociando tarifas más competitivas. La optimización de la integración del producto se vuelve crucial en este proceso. Al analizar cómo se incorpora en el contenido y su resonancia con la audiencia, las marcas pueden ajustar la colocación y presentación del producto para maximizar su impacto y relevancia. Este análisis profundo se facilita gracias al enfoque holístico del método propuesto, el cual permite a las marcas identificar los momentos y lugares dentro del video donde la atención de la mayoría de las personas está centrada, optimizando así su presencia y efectividad en el *Product Placement*.

## **Conclusión**

En el presente capítulo, en base al caso analizado, se logró determinar que el proceso de detección de puntos de contacto en el *Product Placement* junto a la aplicación de un modelo de clasificación adecuado permite optimizar la visualización de la marca en el *Marketing* de contenido al haber mostrado la importancia de identificar y sincronizar los puntos de contacto visual en los consumidores para comprender mejor cómo interactúan con el contenido publicitario. Este análisis no sólo resalta la relevancia de los puntos de

contacto, sino que también presenta un proceso que explora cómo se puede mejorar el *Marketing* de contenido a través de la predicción de la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual, empleando un modelo de clasificación óptimo.

En el contexto del *Marketing* de colocación de productos, resulta esencial estudiar el enfoque de atención de los usuarios. Al analizar las metodologías para la detección de dichos puntos de atención, se evidencia la necesidad de utilizar enfoques precisos y eficientes que permitan identificar con precisión los momentos claves de interacción. Por tal motivo en la primera parte de este capítulo, se desplegaron dos herramientas con el propósito de cuantificar la atención del público objetivo. Tras comparar *WebGazer.js* y *Gaze Recorder*, se determinó la superioridad de este último en términos de precisión, motivo por el cual se optó por su implementación. Posteriormente, se administró a un grupo de 20 sujetos con la finalidad de derivar un punto medio por *Frame*.

Para este propósito, se utilizó el algoritmo de agrupamiento *K-Means*, el cual permitió sincronizar los puntos de contacto visual. Este punto medio, a su vez, se convierte en la variable respuesta en un modelo que busca clasificar si en los *Frames* donde se visualiza la marca, el punto medio se encuentra cercano o distante. Al examinar las metodologías para detectar los puntos de contacto, se puso de manifiesto la necesidad de emplear enfoques precisos y eficaces que permitan identificar con exactitud los momentos críticos de interacción. La sincronización de estos puntos de contacto visual resulta crucial para comprender su influencia en las decisiones de los consumidores.

Los modelos de clasificación evaluados, como *KNN*, *Decision Tree*, *Random Forest*, Regresión Logística y Regresión Logística con *Grid Search*, ofrecen diferentes enfoques para predecir la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual. Cada modelo tiene sus ventajas y limitaciones, por lo que la selección del modelo óptimo depende de varios factores, incluida la naturaleza de los datos. La selección del modelo adecuado es crucial para optimizar la visualización de la marca en el *Marketing* de contenido. Se ha demostrado que la precisión y la eficiencia del modelo de clasificación pueden influir significativamente en la efectividad de las estrategias de *Marketing*. Por lo tanto, es fundamental realizar una evaluación exhaustiva de los diferentes modelos y seleccionar aquel que mejor se adapte a las necesidades y genere una mejor predicción.

El proceso de detección de puntos de contacto visual es un componente esencial en la optimización de la visualización de la marca en el *Marketing* de contenido. Al comprender mejor cómo interactúan los consumidores con el contenido publicitario, las organizaciones pueden ajustar sus estrategias y mejorar su efectividad en términos de visualización de la marca. Esto puede traducirse en una mayor eficiencia en el gasto publicitario y mejores resultados comerciales en general.

## **Conclusión**

El principal resultado alcanzado en el trabajo final de maestría reside en la consolidación de un enfoque integral para la optimización del *Marketing* de contenido a través de la gestión eficiente de datos no estructurados, apoyado en el uso de modelos de redes neuronales. Este trabajo ha destacado la importancia crítica de comprender y aprovechar el vasto conjunto de datos disponibles para mejorar la toma de decisiones estratégicas en el ámbito del *Marketing*. Al analizar en detalle la gestión de datos no estructurados en organizaciones basadas en datos, se ha evidenciado su papel fundamental en la optimización de la visualización de la marca y en la mejora de la efectividad de las estrategias de *Product Placement*. Además, se ha explorado tomando un caso visual cómo la aplicación de modelos de redes neuronales, como herramientas avanzadas de detección y procesamiento de datos, puede contribuir significativamente a maximizar la visualización de la marca en el *Marketing* de contenido, proporcionando así una base sólida para futuras investigaciones y prácticas en este campo en constante evolución.

El objetivo general que guio la elaboración de este trabajo fue desarrollar un proceso de predicción utilizando redes neuronales para estimar la distancia entre la marca PedidosYa y los puntos de contacto visual del espectador en un anuncio televisivo, con el fin de optimizar su visualización. Para su desarrollo, se estableció primero un marco teórico explicando la importancia del análisis de datos no estructurados para las organizaciones que invierten en *Marketing* de contenido. Posteriormente, se identificó la información disponible en un video, como los *frames* y colores, y se profundizó mediante la generación de modelos con *computer vision* capaces de obtener más datos. Luego, se llevó a cabo un seguimiento ocular y su respectiva sincronización para utilizarlo como variable respuesta. Finalmente, se aplicaron diversos modelos predictivos con el fin de predecir la distancia entre la aparición de la marca y el punto medio de contacto visual, encontrando el mejor modelo para el caso bajo análisis y evidenciando los factores que

hacen que la marca sea más visible. Este procedimiento permitió destacar la importancia de la gestión de datos no estructurados en las organizaciones. Aunque se advierten limitaciones en términos de la cantidad de datos, se considera que constituye un significativo aporte inicial para las organizaciones.

La realización de la tesis se estructuró en tres capítulos. En el Capítulo 1 se realizó un análisis de las organizaciones en una sociedad basada en datos, detallando la caracterización y la importancia de las tecnologías de *Big Data* para la gestión organizacional y la generación de valor. Luego, se examinó el papel crucial de los datos no estructurados en las organizaciones, abordando desafíos, oportunidades y la relevancia de la gestión de éstos para el *Marketing*. En el Capítulo 2, se abordó el *Product Placement*, enfocándose en la recolección de datos y la información proporcionada por modelos de detección como las Redes Neuronales Convolucionales. Finalmente, el Capítulo 3 se centró en los puntos de contacto en el *Product Placement* y se presentaron los modelos de clasificación para optimizar la visualización de una marca, destacando el proceso de selección del mejor modelo y los resultados del proceso de detección.

El objetivo del primer capítulo fue evaluar la relevancia y el impacto de la gestión de datos no estructurados en la toma de decisiones de organizaciones. La hipótesis asociada fue que una gestión efectiva de datos no estructurados en organizaciones que implementan estrategias de colocación de productos basadas en datos conducirá a una mejora significativa en la precisión y efectividad de las decisiones tomadas. La caracterización de las organizaciones como entidades basadas en datos y el análisis de la importancia de las tecnologías de *Big Data* para la gestión organizacional proporcionan un contexto sólido para comprender cómo las organizaciones dependen cada vez más de datos estructurados y no estructurados para tomar decisiones estratégicas.

La contribución de este primer capítulo fue una primera aproximación para proporcionar el fundamento y los conceptos necesarios para sustentar que una gestión efectiva de datos no estructurados, en organizaciones que implementan estrategias de colocación de productos basadas en datos, conducirá a una mejora significativa en la precisión y efectividad de las decisiones tomadas. Esto, a su vez, conducirá a la optimización de las estrategias de *Marketing* implementadas. Se analizaron los desafíos y oportunidades asociados con los datos no estructurados, evidenciándose la necesidad de una gestión eficaz de éstos para aprovechar su potencial en la generación de valor para la

organización. Se destacó la relevancia del *Product Placement* como estrategia basada en datos, donde la medición precisa de la exposición se convierte en un factor crítico para evaluar su efectividad.

El segundo capítulo, tuvo por objetivo evaluar como influye el procesamiento de datos no estructurados mediante modelos de detección en la generación de información relevante para el diseño de estrategias de *Product Placement* en organizaciones. La hipótesis aquí planteada es que el adecuado manejo de la recopilación, análisis y procesamiento de datos no estructurados mediante modelos de detección contribuye significativamente a la generación de información relevante para el diseño de estrategias de *Product Placement* en organizaciones.

Mediante el análisis de datos preliminares del *Product Placement* obtenidos del procesamiento de un comercial en video de la marca de PedidosYa, como *frames*, píxeles y colores, se obtuvo una comprensión básica de los elementos esenciales para la identificación de productos en contenido audiovisual. Posteriormente, se profundizó en la metodología de recolección de datos, centrándose en modelos de detección como las Redes Neuronales y las Redes Neuronales Convolucionales. Estos modelos permitieron identificar y extraer información relevante, constituyendo una base sólida para la generación de información pertinente en el diseño de estrategias de *Product Placement*. Además, se examinó la metodología y los modelos de detección empleados, proporcionando un primer acercamiento a una comprensión más profunda de cómo el manejo adecuado de los datos no estructurados, mediante modelos de detección, contribuye a la generación de información valiosa.

Por último, el tercer capítulo tuvo como objetivo optimizar la visualización de la marca en el *Marketing* de contenido a través de la predicción de la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual, empleando un modelo de clasificación óptimo. La hipótesis asociada fue que la utilización de un modelo de clasificación óptimo para predecir la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual permite maximizar la visibilidad de la marca en el *Marketing* de contenido. Para ello, se exploraron dos áreas principales: la detección de puntos de contacto en *el Product Placement* y los modelos de clasificación para optimizar la visualización de la marca.

El desarrollo de este último capítulo consistió en sincronizar los puntos de contacto de 20 usuarios con el video y seleccionar el mejor modelo para presentar los resultados del proceso de detección. Esto implicó identificar el modelo de clasificación óptimo que ofreció la mayor precisión y efectividad en la predicción de la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual. Lo desarrollado en el capítulo constituye un primer paso fundamental en la optimización de la visibilidad de una marca en *Marketing* de contenido al proporcionar un enfoque estructurado y específico para maximizar la eficacia de las estrategias de *Product Placement*. Al mejorar la comprensión de cómo interactúan los espectadores con el contenido publicitario, las organizaciones pueden ajustar sus estrategias y mejorar su efectividad en términos de visibilidad de la marca. Esto puede traducirse en una mayor eficiencia en el gasto publicitario y mejores resultados comerciales en general.

De esta manera, a lo largo de este trabajo, se logra una contribución al campo del *Marketing* de contenido. Se ha logrado proporcionar una comprensión integral sobre la gestión de datos no estructurados y su relevancia en la toma de decisiones estratégicas en organizaciones orientadas a datos. Además, se ha analizado en profundidad cómo la recopilación, el análisis y el procesamiento de estos datos influyen en la generación de información importante para el diseño de estrategias de *Product Placement*. También se ha explorado la optimización de la visualización de una marca en el *Marketing* de contenido mediante la predicción precisa de la distancia entre el *Product Placement* y la sincronización de los puntos de contacto visual, utilizando modelos de clasificación óptimos.

Como resultado general, la gestión de datos no estructurados de video permite recopilar información valiosa, como la elección de colores, tamaños y ubicaciones óptimas para colocar las marcas, mejorando así su visibilidad. Sin embargo, surgen desafíos relacionados con la atención de los usuarios. En este estudio, debido a la brevedad de los videos analizados (uno por cada consumidor de un total de 20), no se consideró el factor de atención. Para investigaciones futuras con videos de mayor duración, será crucial identificar los momentos en que los usuarios desvían su atención y considerar sus preferencias para medir dicha atención, desarrollando estrategias para evitar sesgos.

Para evitar sesgos, si bien puede resultar necesario explicar la finalidad del estudio, se debe realizar sin influir en el comportamiento de los participantes. En futuros estudios,

sería ideal grabar a los usuarios sin que conozcan el propósito exacto del análisis. Otro aspecto relevante es el costo computacional. Es importante tener en cuenta que el tiempo de procesamiento del modelo está directamente relacionado con la duración del video. Videos más largos implican un costo más alto debido al tiempo de procesamiento necesario. A futuro, se podría aplicar el modelo a un *reality show* completo o a una temporada entera de fútbol para medir los cambios de manera continua.

Aunque procesar videos en tiempo real es una opción interesante para investigaciones futuras, actualmente, el mayor costo proviene de la personalización necesaria para la detección de marcas, independientemente de la duración del video. Es esencial identificar las marcas previamente para realizar esta personalización de manera efectiva. Dado que este campo es vanguardista, se requiere una evaluación constante de los modelos utilizados, ya que estos continúan evolucionando.

El sonido también es un factor importante que puede mejorar la visualización de las marcas y debe sincronizarse con su aparición. Integrar el sonido de manera efectiva podría potenciar la atención y la percepción de las marcas. Además, investigar la relación entre la visualización y la recordación de las marcas mediante encuestas a los usuarios podría proporcionar información valiosa sobre el impacto de las estrategias de visualización en la memoria del consumidor.

La elaboración de cada capítulo ha proporcionado una primera base sólida para entender la importancia de los aspectos trabajados en el ámbito del *Marketing* de contenido, destacando tanto los desafíos como las oportunidades que ofrecen. En conjunto, este trabajo constituye un recurso valioso para académicos y profesionales del *Marketing*, al ofrecer un enfoque integral y detallado sobre cómo gestionar y aprovechar eficazmente los datos no estructurados en el diseño de estrategias de *Marketing* de contenido. Los hallazgos y conclusiones aquí presentados tienen el potencial de influir en la práctica y abren la posibilidad de continuarlo en investigaciones futuras, además de contribuir al avance y desarrollo de nuevas herramientas y técnicas para mejorar la efectividad de las estrategias de *Marketing* en la era digital.

## Referencias bibliográficas

- Abele, J. L., & Stone, R. L. (1974). Television audience measurement: The new methodology. *Journal of Marketing Research*, 11(3), 267-276.
- Aguirre, C. (2018). Plan de negocios para emprendimiento en el área de análisis de datos y business intelligence. Universidad de Chile Facultad de Ciencias Físicas y Matemáticas Departamento de Ingeniería Industrial.
- Aja Quiroga, L. (2002). Gestión de información, gestión del conocimiento y gestión de la calidad en las organizaciones. *Acimed*, 10(5), 7-8.
- Armstrong, G., & Kotler, P. (2003). *Marketing: An introduction*. Pearson Educación.
- Artola Moreno, Á. (2019). Clasificación de imágenes usando redes neuronales convolucionales en Python.
- Balasubramanian, S. (1994). Beyond advertising and publicity: Hybrid messages and public policy issues. *Journal of Advertising*, 23(4), 29-46.
- Baños González, M., & Rodríguez García, T. C. (2012). Imagen de marca y product placement. *ESIC*.
- Barro, M. J. F., Pérez, A. S., & Costa, S. M. (2016). Branded content versus product placement. Visibilidad, recuerdo y percepción del consumidor. *Revista de Antropología Social*, 24, 35-52.
- Bassat, L. (2001). *El libro rojo de la publicidad (ideas que mueven montañas)*. Debolsillo.
- Bauer, D., & Bauer, D. (2000). Database-Marketing. Telemarketing: Mit Database Management und neuen Vertriebsstrukturen zum Erfolg, 47-76.
- Belch, G. E., & Belch, M. A. (2014). *Publicidad y promoción: perspectivas de marketing* (19a ed.). McGraw-Hill.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer
- Blattberg, R. C., Kim, B. D., & Neslin, S. A. (2008). Why database marketing? (pp. 13-46). Springer New York.
- Blinn, J. F. (2005). What is a pixel? *IEEE computer graphics and applications*, 25(5), 82-87.
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv preprint arXiv:2004.10934.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). Classification and Regression Trees.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.

- Brown, C., & Johnson, R. (2020). *Detección y análisis de patrones: Una guía práctica*. Springer.
- Brown, J. S., & Hagel III, J. (2012). *The power of pull: How small moves, smartly made, can set big things in motion*. Basic Books.
- Bryman, A., & Bell, E. (2015). *Business Research Methods* (5ta ed.). Oxford University Press.
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.
- Bughin, J., Chui, M., & Manyika, J. (2010). Clouds, big data, and smart assets: Ten tech-enabled business trends to watch. *McKinsey Quarterly*, 56(1), 1-11.
- Calderón, J., Rozo, J., & Sandoval, J. (2017). La inteligencia de negocios y su rol en la agilidad organizacional. *Criterio Libre*, 15(26), 239-258.
- Castells, M. (2004). *La era de la información: economía, sociedad y cultura* (Vol. 1). siglo XXI.
- Cao, L., Yang, F., Li, J., & Li, X. (2017). The challenges of big data quality management. *IEEE Access*, 5, 2654-2663.
- Castells, M (2006). *La sociedad red: una visión global*. Alianza Editorial.
- Castillo, B. T. (2011). *Medios Masivos de Comunicación: una construcción de la realidad*. Pequeñ, 1(1), 108-119.
- Chapman J. & Hall. Brown, S., & Hagel III, J. (2012). *The power of pull: How small moves, smartly made, can set big things in motion*. Basic Books.
- Chávez, K., & Amaya, O. (2021). Solución de big data para el área de comercialización de la empresa inversiones santa maría en el período 2021 bajo el ecosistema de apache hadoop y microsoft azure. Recuperado de [https://repositorio.upao.edu.pe/bitstream/20.500.12759/10141/1/REP\\_KEILITA.CH%c3%81VEZ\\_ORBIT.AMAYA\\_SOLUCION.DE.BIG.DATA.pdf](https://repositorio.upao.edu.pe/bitstream/20.500.12759/10141/1/REP_KEILITA.CH%c3%81VEZ_ORBIT.AMAYA_SOLUCION.DE.BIG.DATA.pdf)
- Chen, H., Chiang, R. , & Storey, V.(2012). Business intelligence and analytics: From big data to big impact. *MIS Quarterly*, 36(4), 1165-1188.
- Chen, M., Mao, S., & Liu, Y. (2014). Big data: A survey. *Mobile Networks and Applications*, 19(2), 171-209.
- Couto, F. (2017). *Gestión de datos de investigación*. Editorial UOC.
- Cover, T., & Hart, P. (1967). Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, 13(1), 21-27.
- d'Astous, A., & Séguin, N. (1999). Consumer reactions to product placement strategies

- in television sponsorships. *European Journal of Marketing*, 33(9/10), 896-910.
- Ente nacional de comunicaciones (2009). Ley 26.522 (Boletín Oficial N° 31.756, 10/10/09)
- Davenport, T. H., y Harris, J. G. (2013). *Competing on analytics: The new science of winning*. Harvard Business Review Press
- Davidaviciene, V., & Al Majzoub, K. (2022). The effect of cultural intelligence, conflict, and transformational leadership on decision-making processes in virtual teams. *Social sciences*, 11(2), 64.
- Díaz-Ramírez, J. (2021). Aprendizaje Automático y Aprendizaje Profundo. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180-181.
- Dolina, R. (2021). La televisión desplazada por las nuevas plataformas digitales y su baja en la cantidad de audiencia. Universidad de Buenos Aires, Facultad de Filosofía y Letras.  
<http://eventosacademicos.filo.uba.ar/index.php/JIAE/IAE2021/paper/viewFile/5687/3521>
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 3-33.
- Forsyth, D. A., & Ponce, J. (2011). *Computer vision: A modern approach*. Prentice Hall.
- Gantz, J., & Reinsel, D. (2020). *IDC Data Age 2025: The Digitization of the World from Edge to Core*. Seagate Technology LLC. Consultado el 25 de abril de 2023, desde <https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf>
- García, C. M., & Gallego Gil, D. J. (2002). Tecnologías de la información y la comunicación. *Revista de Educación*, 329, 181-205.  
<https://redined.educacion.gob.es/xmlui/handle/11162/67177>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Gartner. (2012). Gartner's big data definition. Gartner. Retrieved from <https://www.gartner.com/en/information-technology/glossary/big-data>
- Hanna, R., Rohm A., Crittenden, V., (2011). We're all connected: The power of the social media ecosystem, *Business Horizons*, Volume 54, Issue 3, 2011, Pages 265-273, ISSN 0007-6813, <https://doi.org/10.1016/j.bushor.2011.01.007>.
- Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A K-Means Clustering Algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1), 100-108.
- Haskel, J., & Westlake, S. (2017). *Capitalism without capital*. Princeton University Press. ISBN: 9780691175034

- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression*. Wiley.
- Hupperz, M. J., Gür, I., Möller, F., & Otto, B. (2021). What is a data-driven organization? In *AMCIS*.
- IDC. (2012). Nuevas Tendencias Tecnológicas han Entrado a AL. Recuperado de <http://mx.idclatin.com/releases/news.aspx?id=1433>).
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R*. Springer.
- Jeffery, M. (2010). *Data-driven marketing: the 15 metrics everyone in marketing should know*. John Wiley & Sons.
- Jocher, G., Chaurasia, A., Stoken, A., Borovec, J., Kwon, Y., Michael, K. Tao, X., Fang, J., Imyh, X... & Jain, M. (2022). *ultralytics/YOLOv5: v7. 0-YOLOv5 sota realtime instance segmentation*. Zenodo.
- Jurafsky, D., & Martin, J. H. (2019). *Speech and language processing* (3rd ed.). Pearson.
- Kang, Y., Cai, Z., Tan, C.-W., Huang, Q., & Liu, H. (2020). Natural language processing (NLP) in management research: A literature review. *Journal of Management Analytics*, 1–34. doi:10.1080/23270012.2020.1756
- Katamesh, N., Abu-Elnasr, O., & Elmougy, S. (2021). Deep Learning Multimodal for Unstructured and Semi-Structured Textual Documents Classification. *Computers, Materials & Continua*, 68(1).
- Katz, E. R. (2016). *The Media Handbook: A Complete Guide to Advertising Media Selection, Planning, Research, and Buying*. Routledge.
- Khan, M. A. (2016). A survey of security issues for cloud computing. *Journal of Network and Computer Applications*, 71, 11–29. DOI:10.1016/j.jnca.2016.05.010
- Kitchin, R. (2014). Big data, new epistemologies and paradigm shifts. *Big Data & Society*, 1(1), 2053951714528481. <https://doi.org/10.1177/2053951714528481>
- Kotler, P., & Armstrong, G. (2016). *Principios de marketing*. Pearson.
- Kongmanon, J., & Petison, P. (2022). What do you see and what do you recall?: Using eye tracking to understand product placement. *Cogent Business & Management*, 9(1), 2120263.

Lalaleo-Analuisa, F., Bonilla-Jurado, D., & Vilcacundo-Pérez, S. (2023). Relación entre la estrategia de comunicación y la toma de decisiones en el desarrollo de marketing mix digital en Multisa CAD como empresa 4.0. *REVISTA DE INVESTIGACIÓN SIGMA*, 10(01).

Laney, D. (2001) 3D Data Management: Controlling Data Volume, Velocity and Variety. META Group Research Note, 6

Larrañaga, P., Inza, I., & Moujahid, A. (1997). Tema 6. clasificadores bayesianos. Departamento de Ciencias de la Computación e Inteligencia Artificial– Universidad del País Vasco-Euskal Herriko Unibertsitatea.

Law, S., & Braun, K. A. (2000). I'll have what she's having: Gauging the impact of product placement on viewers. *Psychology & Marketing*, 17(12), 1059-1075.

Lee, I. (2017). Big data: Dimensions, evolution, impacts, and challenges. *Business Horizons*, 60(3), 293–303. doi: <https://doi.org/10.1016/j.bushor.2017.01.004>

Lerman, P. M., (1980), Fitting Segmented Regression Models by Grid Search, *Journal of the Royal Statistical Society Series C*, 29, issue 1, p. 77-84.

Lloyd, S. (1982). Least squares quantization in PCM. *IEEE Transactions on Information Theory*, 28(2), 129-137.

Macionis, J. J., & Plummer, K. (2012). *Sociología*. Pearson Educación.

Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to information retrieval*. Cambridge University Press.

McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J., & Barton, D. (2012). Big data: the management revolution. *Harvard business review*, 90(10), 60-68. <https://www.tarjomefa.com/wp-content/uploads/2017/04/6539-English-TarjomeFa-1.pdf>

Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A. H. (2011). Big data: The next frontier for innovation, competition, and productivity. *McKinsey Global Institute*, 1(4), 1-11.

Mayer-Schönberger, V., & Cukier, K. (2013). *Big data: A revolution that will transform how we live, work, and think*. Houghton Mifflin Harcourt.

Meyer, S., Wang, O., Zimmer, H., Grosse, M., & Sorkine-Hornung, A. (2015). Phase-based frame interpolation for video. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1410-1418).

Michael, E. (1990). Porter. *The competitive Advantage of Nations*.

Mitchell, T. (1997). *Machine learning*. McGraw Hill.

- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). Introduction to linear regression analysis. John Wiley & Sons
- Morgado, M. M. (2007). Del product placement no se escapa nadie.
- Moujahid, A., Inza, I., & Larranaga, P. (2019). Tema 5. Clasificadores K-NN. Departamento de Ciencias de la Computación e inteligencia artificial, Universidad del País Vasco-Euskal Herriko Unibertsitatea, 3, 1.
- Neubeck, A., & Van Gool, L. (2006, August). Efficient non-maximum suppression. In 18th international conference on pattern recognition (ICPR'06) (Vol. 3, pp. 850-855). IEEE.
- Nielsen, M. A. (2015). Neural networks and deep learning (Vol. 25, pp. 15-24). San Francisco, CA, USA: Determination press.
- Olabe, X. B. (1998). Redes neuronales artificiales y sus aplicaciones. Publicaciones de la Escuela de Ingenieros.
- Osorio, D. S. Á., Contreras, A. C., & León, J. C. M. (2011). Modelos digitales batimétricos generados por métodos de interpolación IDW, KRIGING, SHEPARD y B-SPLINE en el Archipiélago de Islas del Rosario. UD y la geomática, (5), 3-14
- Papoutsaki, A., Sangkloy, P., Laskey, J., Daskalova, N., Huang, J., & Hays, J. (2016). WebGazer: Seguimiento ocular escalable con cámara web mediante interacciones del usuario. En Actas de la Veinticincoava Conferencia Internacional Conjunta sobre Inteligencia Artificial (IJCAI) (pp. 3921-3927).
- Pose, M. G. (2009). Introducción a las redes de neuronas artificiales. Departamento de Tecnologías de la Información y las Comunicaciones. Universidad da Coruña.
- PQ Media. (2020). Branded entertainment marketing forecast 2020-24: PQ Media. Recuperado de <https://pqmedia.com/product/branded-entertainment-marketing-forecast-2020-24/>
- Raghupathi, W., & Raghupathi, V. (2014). Big data analytics in healthcare: Promise and potential. Health Information Science and Systems, 2(1), 3.
- Rainer, R. K., Cegielski, C. G., & Splettstoesser-Hogeterp, I. (2017). Introduction to information systems: Supporting and
- Redmon, J., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. En Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Reichheld, F. F., & Sasser, W. E. (1990). Zero defections: quality comes to services. 1990, 68(5), 105-111.

Rhodes T, Lancaster K. Evidence-making interventions in health: A conceptual framing. *Soc Sci Med.* 2019 Oct; 238:112488. doi: 10.1016/j.socscimed.2019.112488. Epub 2019 Aug 10. PMID: 31422173.

Rodríguez Schwarz, C. A. (2016). Las tasas de recuerdo de los emplazamientos de producto en las series de televisión españolas.

Ronft, S., Friedrich, M. G., & Sofiullah, M. (2023). Effect of product placement labeling on visual product and brand reception—an empirical eye tracking study. *Journal of Marketing Communications*, 1-16.

Rumpf, C., Boronczyk, F., & Breuer, C. (2019). Predicting consumer gaze hits: A simulation model of visual attention to dynamic marketing stimuli. *Journal of Business Research*. doi: 10.1016/j.jbusres.2019.03.034

Russell, C. A. (2002). Investigating the Effectiveness of Product Placements in Television Shows: The Role of Modality and Plot Connection Congruence on Brand Memory and Attitude. *Journal of Consumer Research*, 29(3), 306–318. <https://doi.org/10.1086/344432>

Russell, C. A., & Stern, B. B. (2006). Consumers, characters, and products. *Journal of Advertising*, 35(1), 7–21. <https://doi.org/10.2753/JOA0091-3367350101>

Russell, S. J., & Norvig, P. (2022). *Artificial intelligence: A modern approach* (5th ed.). Pearson.

Salaberry, N. (2022) *Gestión responsable de datos en el Estado argentino. La Privacidad Diferencial como propuesta para la protección de datos personales.*

Schmarzo, B. (2013). *Big Data: Understanding How Data Powers Big Business.* Wiley.  
Szeliski, R. (2010). *Computer vision: Algorithms and applications.* Springer.

Shah, N. D., Steyerberg, E. W., & Kent, D. M. (2018). Big data and predictive analytics: recalibrating expectations. *Jama*, 320(1), 27-28.

Shen, C. Y., Reed, H. L., & Foley, T. A. (1993). Shepard's interpolation for solution-adaptive methods. *Journal of computational physics*, 106(1), 52-61.

Shinde, P. P., & Shah, S. (2018, August). A review of machine learning and deep learning applications. In 2018 Fourth international conference on computing communication control and automation (ICCUBEA) (pp. 1-6). IEEE.

Smith, A. (2018). *Fundamentos de la detección de datos.* Editorial Tecnos.

Smith, J., & Brown, A. (2018). *Marketing Management: An Introduction.* Oxford University Press.

Somaraj, S., & Hussain, M. A. (2016, February). A novel image encryption technique using RGB pixel displacement for color images. In 2016 IEEE 6th International Conference on Advanced Computing (IACC) (pp. 275-279). IEEE.

Song, H., Lee, J., Kim, T. J., Lee, K. H., Kim, B., & Seo, J. (2016). GazeDx: Interactive visual analytics framework for comparative gaze analysis with volumetric medical images. *IEEE transactions on visualization and computer graphics*, 23(1), 311-320.

Statista (2024). <https://es.statista.com/estadisticas/600877/gasto-mundial-en-publicidad/>

The Economist. (2016). Artificial Intelligence in the Real World: The business case takes shape. Consultado el 25 de abril de 2023, desde [https://impact.economist.com/perspectives/sites/default/files/Artificial\\_intelligence\\_in\\_the\\_real\\_world\\_1.pdf](https://impact.economist.com/perspectives/sites/default/files/Artificial_intelligence_in_the_real_world_1.pdf)

Torrano Palazón, J., & Flores López, E. (2007). Factores determinantes de la actitud hacia el product placement.

Velarde, M. S., & Lau, E. (2010). Product placement en el cine, análisis publicitario de la categoría Autos a través de diversos filmes: medición de factores de influencia que afecten los objetivos publicitarios. *Revista de comunicación*, (9), 60-94.

Vidal, M. E., Mora, M., & Méndez, D. (2018). Gestión de información y conocimiento en organizaciones: una revisión sistemática. *Información, Cultura y Sociedad*, (38), 121-146.

Vidal, G. P. (2016). *Marketing una herramienta para el crecimiento*. Ediciones de la U.

Villalobos-Arias, L., Quesada-López, C., Martínez, A., & Jenkins, M. (2021). Técnicas de ajuste de hiperparámetros de algoritmos de aprendizaje automático para la estimación de esfuerzo: un mapeo de literatura. *Revista Ibérica de Sistemas e Tecnologías de Informação*, (E42), 305-318.

Visa, S., Ramsay, B., Ralescu, A. L., & Van Der Knaap, E. (2011). Confusion matrix-based feature selection. *Maics*, 710(1), 120-127.

Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2021). YOLOv5: A Model Architecture Overview. *Ultralytics*.

Westerman, G., Bonnet, D., & McAfee, A. (2014). *Leading digital: Turning technology into business transformation*. Harvard Business Review Press.

Yang, M., & Roskos-Ewoldsen, D. R. (2007). The effectiveness of brand placements in the movies: Levels of placements, explicit and implicit memory, and brand-choice behavior. *Journal of Communication*, 57(3), 469–489. <https://doi.org/10.1111/j.1460-2466.2007.00353.x>

Zhang, L., Wang, S., & Liu, B. (2018). Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1253. doi:10.1002/widm.1253

## Anexo

### Códigos aplicados

Se anexan los códigos implementados en Python.

Para poder correr los códigos se requiere información que esta alojada en una carpeta de drive:

[https://drive.google.com/drive/folders/1RBuAN\\_axDjSZ1wAkrTYKCO4A5maRM-x?usp=sharing](https://drive.google.com/drive/folders/1RBuAN_axDjSZ1wAkrTYKCO4A5maRM-x?usp=sharing)

Video: <https://www.youtube.com/watch?v=CNiAAbfkNzY>

#### 1. Selección de *frames* desde el video de la marca.

<https://colab.research.google.com/drive/14ZG6fl-qTmGbNX32Ao9s1p-BkIIs9-Kt?usp=sharing>

en esta carpeta se pueden ver cada uno de los frames:

[https://drive.google.com/drive/folders/1FOrLCI9RWxPx8EB2CRicS-04F7Thsr\\_5?usp=sharing](https://drive.google.com/drive/folders/1FOrLCI9RWxPx8EB2CRicS-04F7Thsr_5?usp=sharing)

#### 2. Detección de colores por cada uno de los *Frames*.

[https://colab.research.google.com/drive/1TI2CEIJO03ckFR9JFM0Fnebg\\_17MVIQW](https://colab.research.google.com/drive/1TI2CEIJO03ckFR9JFM0Fnebg_17MVIQW)

Se genera un Excel con la mediana, media y la moda de los colores por *frame*:

[https://docs.google.com/spreadsheets/d/15633HQZcWW8u4xSFRD2O\\_9qYoXasIO45/edit?usp=drive\\_link&oid=111574999816080148196&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/15633HQZcWW8u4xSFRD2O_9qYoXasIO45/edit?usp=drive_link&oid=111574999816080148196&rtpof=true&sd=true)

#### 3. Detección de las marcas

***Mask R-CNN:***

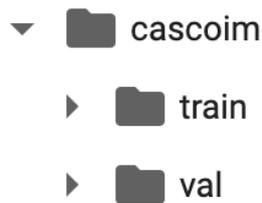
El código fue tomado de un código previamente realizado por David Revelo Luna

Se realizo la detección de polígonos con: <https://www.makesense.ai/>

Se crean 2 carpetas una de Train y otra de Val, en estas están las imágenes y un archivo en formato *json* con los polígonos de cada imagen

[https://drive.google.com/drive/folders/1DyAhWvAjEd61EsvD-1M3kTIyJmXCfJ31?usp=drive\\_link](https://drive.google.com/drive/folders/1DyAhWvAjEd61EsvD-1M3kTIyJmXCfJ31?usp=drive_link)

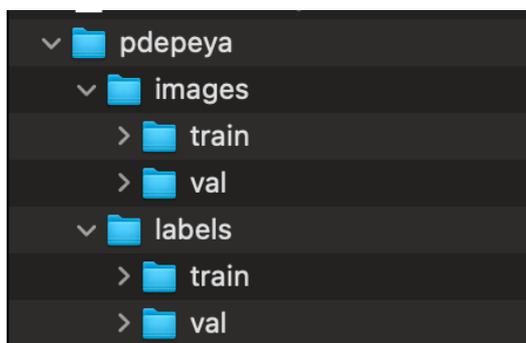
se debe arrastrar la carpeta a colab pero con el nombre de cascoim:



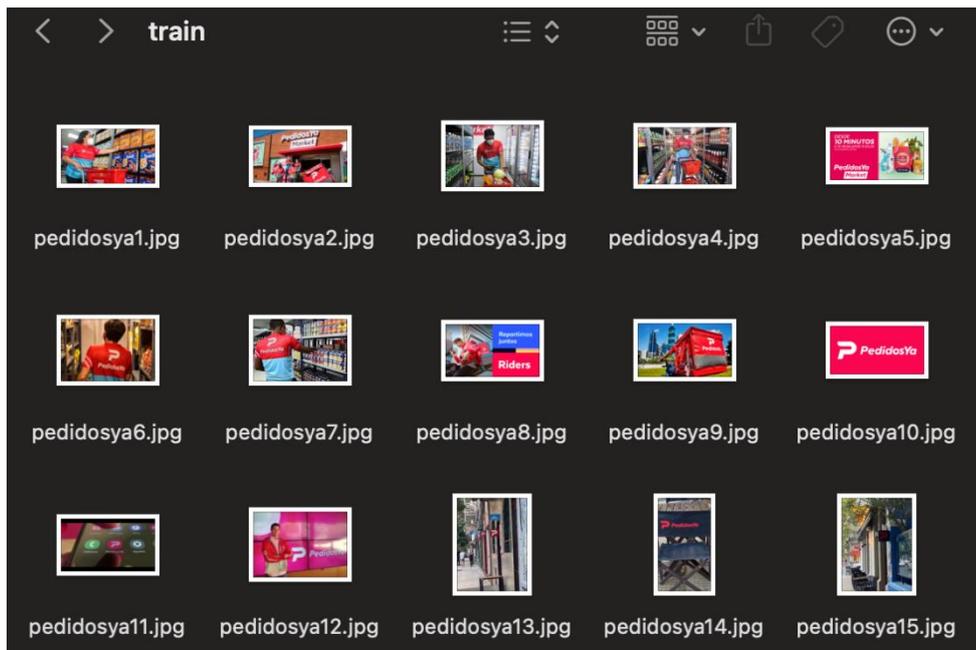
<https://drive.google.com/file/d/1uf4rYw1YoAV9OZKmD7bXxDDrOWQeZ9sx/view?usp=sharing>

### **YOLO:**

Se debe tener un set de imágenes donde aparezcan las marcas, y se debe dividir en 2 carpetas obj y test en YOLOv4 y *Train* y Val en YOLOv5, mediante el programa labellmg (que corre solo en Windows) se realiza la detección de marcas y se genera en otra carpeta un archivo en txt que guarda las coordenadas de las marcas. Estos archivos son los que permitirán realizar la detección de marcas



Por ejemplo, en *train* están estas imágenes



Y después se guardan sus respectivas coordenadas



YOLOv4:

<https://drive.google.com/file/d/18-16MSo5-gba0JfNlhTnXKD0ZtUhSMZA/view?usp=sharing>

YOLOv5:

[https://colab.research.google.com/drive/1G8LpMsQaofel31NuYCJLr3\\_UQ3Rgr0P1#scrollTo=8vIGQJcYBo7O](https://colab.research.google.com/drive/1G8LpMsQaofel31NuYCJLr3_UQ3Rgr0P1#scrollTo=8vIGQJcYBo7O)

Al decidir usar YOLOv5 se obtienen los *frames* detectados por el modelo:

[https://drive.google.com/drive/folders/1yrQEB44JF\\_XKUTOMr1HoNH5oKgCctoat?usp=drive\\_link](https://drive.google.com/drive/folders/1yrQEB44JF_XKUTOMr1HoNH5oKgCctoat?usp=drive_link)

Y el excel con la información correspondiente a cada *frame*:

[https://docs.google.com/spreadsheets/d/1ApiaWLcVpX7pMA9s0t5i0e9bMk5i8Z1e/edit?usp=drive\\_link&oid=111574999816080148196&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/1ApiaWLcVpX7pMA9s0t5i0e9bMk5i8Z1e/edit?usp=drive_link&oid=111574999816080148196&rtpof=true&sd=true)

adicionalmente se deja un archivo solo con los *frames* donde se detectó la marca:

<https://colab.research.google.com/drive/1MW2Ls9I73jEX-CYlhrdgQK08jgtwLj4y?usp=sharing>

se muestran los *frames*

[https://drive.google.com/drive/folders/1kw1BRwiCehgpXJRA-6S0ol9szvX2wgCT?usp=drive\\_link](https://drive.google.com/drive/folders/1kw1BRwiCehgpXJRA-6S0ol9szvX2wgCT?usp=drive_link)

#### **4. Detección de colores por aparición de las marcas**

<https://drive.google.com/file/d/1jw6elJ4zk8JN7fAYN3pj1NqQW8kbiSF5/view?usp=sharing>

Se guarda el excel con los *frames* correspondientes

[https://docs.google.com/spreadsheets/d/1ctf8t1uhjdK9NvV8IU9PnNqgyiv85Pc3/edit?usp=drive\\_link&oid=111574999816080148196&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/1ctf8t1uhjdK9NvV8IU9PnNqgyiv85Pc3/edit?usp=drive_link&oid=111574999816080148196&rtpof=true&sd=true)

#### **5. Igualar el número de *frames* por video**

Se suben todos los videos procesados:

[https://drive.google.com/drive/folders/1J1JFIJ8TP9dR1x03Go4\\_AOeSEJ8R9uob?usp=drive\\_link](https://drive.google.com/drive/folders/1J1JFIJ8TP9dR1x03Go4_AOeSEJ8R9uob?usp=drive_link)

Para que se puedan comparar es necesario que todos tengan FPS iguales:

<https://drive.google.com/file/d/1JVkX7RSFibzCInLHusfxNlmAdE8nqEG8/view?usp=sharing>

#### **6. Detección de los puntos generados por *Gaze Recorder*, obteniendo coordenadas**

Para poder obtener las coordenadas de la visualización por persona, se realiza una detección con YOLOv5, personalizada, siendo el mapa de calor la imagen a

detectar y después se aplica a cada video de las personas (previamente teniendo todos 25 fps)

[https://drive.google.com/file/d/1SiddKJ1Ag1ciURGEAp04D22WP8cyvgGh/view?usp=drive\\_link](https://drive.google.com/file/d/1SiddKJ1Ag1ciURGEAp04D22WP8cyvgGh/view?usp=drive_link)

Se tienen cada uno de los Excel generado por persona y su unión:

[https://drive.google.com/drive/folders/1u3VPDw19l47XyyI9trgMmO9I78Sh9Sjw?usp=drive\\_link](https://drive.google.com/drive/folders/1u3VPDw19l47XyyI9trgMmO9I78Sh9Sjw?usp=drive_link)

## **7. Generación del punto central**

Se genera el punto central

[https://drive.google.com/file/d/18f8jwq6dmX-1CfI7ja8EhfCzsKDTD54r/view?usp=drive\\_link](https://drive.google.com/file/d/18f8jwq6dmX-1CfI7ja8EhfCzsKDTD54r/view?usp=drive_link)

Se guarda la información en un Excel:

[https://docs.google.com/spreadsheets/d/1Rq0RATRZ6JGeSTnORCrvmgpmHYI8czDo/edit?usp=drive\\_link&oid=111574999816080148196&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/1Rq0RATRZ6JGeSTnORCrvmgpmHYI8czDo/edit?usp=drive_link&oid=111574999816080148196&rtpof=true&sd=true)

## **8. Pruebas de modelos de clasificación.**

Se trabaja con la base que une toda la información previamente recopilada:

[https://docs.google.com/spreadsheets/d/1gfehyhIP0OggpAMqy4X-RCcA3OWghC5w/edit?usp=drive\\_link&oid=111574999816080148196&rtpof=true&sd=true](https://docs.google.com/spreadsheets/d/1gfehyhIP0OggpAMqy4X-RCcA3OWghC5w/edit?usp=drive_link&oid=111574999816080148196&rtpof=true&sd=true)

y se realizan las pruebas de los modelos de clasificación:

[https://colab.research.google.com/drive/1cLuJcf23kVcyluYQx-Uq8h0Z86WX7ETn?usp=drive\\_link](https://colab.research.google.com/drive/1cLuJcf23kVcyluYQx-Uq8h0Z86WX7ETn?usp=drive_link)