

Clasificación de imágenes con redes neuronales mejora el comportamiento del consumidor en estudiantes universitarios

Image classification with neural networks improves consumer behavior in college students

Recibido: 02/06/2025 - Aceptado: 30/08/2025

Roberto Jose María Casas Miranda

<https://orcid.org/0000-0002-2648-167X>

rcasas@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Ivan Crispín Sánchez

<https://orcid.org/0000-0001-5980-6621>

icrispin@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Maritza Raquel Cabana Cáceres

<https://orcid.org/0000-0002-3442-5950>

mcabana@unfv.edu.pe

Universidad Nacional Federico Villarreal. Lima, Perú

Jorge Santiago Nolasco Valenzuela

<https://orcid.org/0000-0002-3070-8400>

jstv57@hotmail.com

Universidad Nacional Federico Villarreal. Lima, Perú

Luz Elena Nolasco Valenzuela

<https://orcid.org/0009-0005-8056-6630>

luznolasvalen@gmail.com

Universidad Nacional Federico Villarreal. Lima, Perú

Resumen

El estudio tuvo el objetivo de determinar de qué manera el clasificador de imágenes con redes neuronales (RN) mejora el comportamiento del consumidor en estudiantes universitarios. Se planteó una investigación de tipo aplicado, con un diseño preexperimental y nivel explicativo. Se recolectaron y procesaron datos mediante técnicas no participativas, analizando la interacción digital de estudiantes universitarios. Los datos fueron limpiados y organizados para su análisis, en el que se aplicaron técnicas de Machine Learning. El uso de TensorFlow y TensorFlow Datasets simplificó el preprocesamiento y entrenamiento del modelo, asegurando un flujo eficiente y un desempeño optimizado mediante la normalización de imágenes y la configuración de lotes de datos. El modelo empleó visualizaciones detalladas con indicadores claros para analizar su rendimiento, destacando aciertos y errores, lo que facilitó su interpretación y ajuste. El modelo preentrenado VGG16, ajustado en 15 épocas, alcanzó una precisión de validación del 97.4 %, evidenciando su alta eficacia en datos no vistos. Los resultados destacan el impacto transformador de las CNNs en la clasificación de productos, mejorando la experiencia del usuario y optimizando la satisfacción y percepción del consumidor en plataformas de moda digitales. La implementación del clasificador de imágenes basado en RN mejoró significativamente la experiencia del usuario, pasando de una percepción negativa a un 90% de evaluaciones positivas. La prueba de Wilcoxon confirmó que este cambio refleja una mejora real en el comportamiento y las decisiones de los estudiantes universitarios como consumidores.

Palabras clave: redes neuronales, clasificador de imágenes, machine learning

Abstract

The study aimed to determine how image classification using neural networks (NN) improves consumer behavior among university students. An applied research study was proposed, with a pre-experimental design and explanatory level. Data was collected and processed using non-participatory techniques, analyzing the digital

interaction of university students. The data was cleaned and organized for analysis, in which machine learning techniques were applied. The use of TensorFlow and TensorFlow Datasets simplified the preprocessing and training of the model, ensuring efficient flow and optimized performance through image normalization and data batch configuration. The model used detailed visualizations with clear indicators to analyze its performance, highlighting successes and errors, which facilitated its interpretation and adjustment. The pre-trained VGG16 model, adjusted in 15 epochs, achieved a validation accuracy of 97.4%, demonstrating its high effectiveness on unseen data. The results highlight the transformative impact of CNNs on product classification, improving the user experience and optimizing consumer satisfaction and perception on digital fashion platforms. The implementation of the RN-based image classifier significantly improved the user experience, shifting from a negative perception to 90% positive ratings. The Wilcoxon test confirmed that this change reflects a real improvement in the behavior and decisions of college students as consumers.

Keywords: neural networks, image classifier, machine learning

Introducción

En la actualidad, la rapidez de los avances tecnológicos y la creciente digitalización han transformado radicalmente diversas esferas de la vida cotidiana, con la inteligencia artificial (IA) y el aprendizaje profundo emergiendo en fuerzas transformadoras en numerosos sectores (Akbiyik, 2019). La clasificación de imágenes mediante redes neuronales, en particular, se ha establecido como un componente central en esta revolución tecnológica. Desde su aplicación en áreas críticas como la medicina hasta su integración en estrategias publicitarias avanzadas, estas tecnologías están cambiando la forma en que interactuamos con el mundo visual (Artola, 2019).

En Europa, el uso de redes neuronales ha sido ampliamente investigado y adoptado, destacándose su capacidad para mejorar la precisión en la segmentación de mercados y la personalización de campañas de marketing (Bennett y Lemoine, 2019). En América, esta tendencia se ha intensificado, con estudios que demuestran cómo estos avances pueden influir en la toma de decisiones de compra, especialmente entre grupos demográficos jóvenes (Davenport y Ronanki, 2018). En este contexto, Perú, y en particular Lima, presenta un panorama único donde la adopción de tecnologías emergentes es menos explorada, especialmente en el sector universitario.

Este trabajo de investigación tiene como objetivo examinar cómo la clasificación de imágenes basada en redes neuronales puede modelar, impactar y predecir las preferencias de consumo entre los estudiantes universitarios. Se busca ofrecer información valiosa que contribuya a la comprensión de las estrategias de marketing digital, especialmente aquellas que utilizan contenido visual personalizado.

En América Latina, las diferencias en la percepción de confianza de los consumidores son evidentes, siendo Brasil un caso donde la confianza en las compras en línea es notablemente alta, a diferencia de Perú, donde aún persisten desafíos significativos en la motivación de compra en plataformas digitales (Hurwitz y Kirsch, 2018). Este fenómeno resalta la desconexión que muchos consumidores experimentan, evitando productos que pueden no resonar con sus expectativas o experiencias previas.

Por lo tanto, se plantea el siguiente problema general: ¿De qué manera el clasificador de imágenes con redes neuronales mejora el comportamiento del consumidor en plataformas digitales en estudiantes universitarios? Y los problemas específicos: 1) ¿De qué manera el clasificador de imágenes con R.N. mejora la motivación del comportamiento del consumidor en estudiantes universitarios? 2) ¿De qué manera el clasificador de imágenes con R.N. mejora la percepción del comportamiento del consumidor en estudiantes universitarios? 3) ¿De qué manera el clasificador de imágenes con R.N. mejora el aprendizaje del comportamiento del consumidor en estudiantes universitarios? y 4) ¿De qué manera el clasificador de imágenes con R.N. mejora la actitud del comportamiento del consumidor en estudiantes universitarios?

Además, se plantea como objetivo general: Determinar de qué manera el clasificador de imágenes con R.N. mejora el comportamiento del consumidor en estudiantes universitarios. Los objetivos específicos son: 1) Determinar de qué manera el clasificador de imágenes con R.N. mejora la motivación del comportamiento del consumidor en estudiantes universitarios. 2) Determinar de qué manera el clasificador de imágenes con R.N. mejora la percepción del comportamiento del consumidor en estudiantes universitarios. 3) Determinar de qué manera el clasificador de imágenes con R.N. mejora el aprendizaje del comportamiento del consumidor en estudiantes universitarios. y 4) Determinar de qué manera el clasificador de imágenes con R.N. mejora la actitud del comportamiento del consumidor en plataformas digitales en estudiantes universitarios.

Finalmente, se propone como hipótesis general: El clasificador de imágenes basado en R.N. mejora el comportamiento del consumidor entre estudiantes universitarios. Las hipótesis específicas son: 1) El clasificador

de imágenes basado en R.N. mejora la motivación del comportamiento del consumidor en estudiantes universitarios. 2) El clasificador de imágenes basado en R.N. mejora la percepción del comportamiento del consumidor en estudiantes universitarios. 3) El clasificador de imágenes basado en R.N. mejora el aprendizaje del comportamiento del consumidor en estudiantes universitarios. y 4) El clasificador de imágenes basado en R.N. mejora la actitud del comportamiento del consumidor en estudiantes universitarios.

La investigación sobre la clasificación de imágenes con redes neuronales y su impacto en el comportamiento del consumidor en estudiantes universitarios es muy importante, ya que este grupo representa una parte significativa del mercado que adopta rápidamente nuevas tecnologías. Al comprender cómo estas herramientas influyen en sus decisiones de compra, las empresas pueden personalizar sus estrategias de marketing digital para mejorar la experiencia del consumidor y aumentar la tasa de conversión. Además, los hallazgos de este estudio ofrecerán a las instituciones educativas perspectivas valiosas sobre cómo integrar tecnologías emergentes en sus currículos, preparando a los estudiantes para un mercado laboral en constante evolución.

Por otro lado, Kumar et al. (2022), en su estudio sobre clasificación de imágenes, destacan la importancia de las Redes Neuronales Convolucionales (CNN) y de sistemas eficientes de procesamiento para la generación de mapas temáticos, resaltan la necesidad de seleccionar cuidadosamente las características de datos y emplear técnicas de clasificación como árboles de decisión y métodos basados en conocimiento, esenciales para integrar información de múltiples fuentes. Además, subrayan el potencial de integrar GIS, teledetección y sistemas expertos, un campo emergente que requiere mayor investigación para perfeccionar los procesos de clasificación. El artículo también analiza cómo el aprendizaje profundo y la visión por computadora, mediante CNNs, pueden mejorar la precisión de clasificación combinando características de distintas capas de estas redes. Para demostrarlo, desarrollaron un modelo con el conjunto de datos CIFAR10 utilizando Keras como API y el método de descenso de gradiente estocástico para la optimización.

Ferreira (2021), en su estudio, examina cómo los consumidores interactúan con estas tecnologías en el ámbito del marketing. El estudio analiza su impacto en la experiencia del cliente a lo largo del proceso de compra, desde la búsqueda de información hasta el soporte postventa, tanto en entornos digitales como físicos. Enfocándose en los asistentes personales controlados por voz, Ferreira explora cómo estos dispositivos generan emociones similares a las relaciones interpersonales, como pasión y compromiso, fomentando comportamientos valiosos para las empresas. La investigación se estructura en dos partes: la primera analiza cómo las emociones relacionadas con el amor del consumidor influyen en la lealtad hacia estas tecnologías, apoyándose en teorías como el modelo S-O-R y la Teoría Triangular del Amor. La segunda examina cómo diferentes dimensiones de la experiencia del consumidor impactan en el apego hacia los asistentes de voz y cómo este apego afecta respuestas transaccionales, como la compra, y no transaccionales, como la recomendación. Este análisis utiliza marcos teóricos como el modelo S-O-R, la Teoría del Apego y el brand engagement. El trabajo ofrece una visión integral de las dinámicas emocionales y conductuales entre los consumidores y las tecnologías inteligentes, aportando valiosas ideas para mejorar estrategias de marketing y fortalecer la relación entre marcas y usuarios.

Briones (2020), en su investigación, analiza la importancia de la experiencia del consumidor como un elemento clave para destacar en un mercado competitivo. Enfocado en el centro comercial de Cajamarca durante 2019, el estudio tuvo como objetivo principal examinar la relación entre la experiencia del cliente y su nivel de satisfacción. Para ello, se empleó un diseño de investigación correlacional y descriptivo, aplicando encuestas a una muestra de 385 clientes. Los datos recolectados fueron analizados con herramientas estadísticas como Excel y SPSS 25, y su fiabilidad se verificó mediante el coeficiente de Cronbach. Los resultados mostraron una relación significativa y directa entre la experiencia del cliente y su satisfacción, evidenciada por un coeficiente de Pearson de 0.386. Este hallazgo indica que al mejorar la experiencia que ofrece el centro comercial, también se incrementa la satisfacción de los compradores. Si bien se concluye que el centro comercial proporciona una experiencia excelente que mantiene a sus clientes satisfechos, el estudio señala que aún existen aspectos que no cumplen completamente con las expectativas del público objetivo, lo que representa una oportunidad para seguir mejorando su propuesta de valor.

Artola (2019) analiza el impacto de la Inteligencia Artificial (IA), el Machine Learning (ML) y el Deep Learning (DL) en la tecnología y la vida cotidiana. La IA, como rama de la computación que emula actividades humanas, ha dado lugar al ML, centrado en el aprendizaje automático, y al DL, que replica el procesamiento de datos del cerebro humano mediante redes neuronales. Estas tecnologías tienen aplicaciones diversas, como la detección de rostros y la generación de evaluaciones médicas. El estudio se enfoca en las redes neuronales convolucionales, esenciales para el análisis y la categorización de imágenes, y en cómo entrenarlas para maximizar precisión, sensibilidad y especificidad. Además, aborda los lenguajes de programación más usados en

IA, las bases de datos para procesamiento y el desempeño de estas redes, destacando tanto su fundamentación teórica como su aplicación práctica en problemas reales.

En conjunto, estos estudios resaltan la influencia de la experiencia y las emociones del usuario en su satisfacción y comportamiento, mientras destacan el papel de la IA y el aprendizaje profundo en la optimización de procesos clave, subrayando la importancia de enfoques innovadores para estrategias de marketing y análisis más efectivas.

Variable independiente

X: Clasificación de imágenes con redes neuronales.

Las redes neuronales artificiales (RN) son esenciales en el desarrollo de la inteligencia artificial, especialmente en la clasificación de imágenes. Estas redes son eficaces para identificar patrones en datos visuales, mejorando la precisión de clasificación al aprender de grandes cantidades de datos (Goodfellow et al., 2016). El uso de redes neuronales profundas, particularmente las redes neuronales convolucionales (CNN), ha demostrado ser relevante, ya que permite etiquetar imágenes basándose en características específicas (Li et al., 2023).

Desde 2020, se han introducido innovaciones en CNN que abordan limitaciones como la "maldición de la dimensionalidad", logrando una eficiente convergencia en la clasificación (Kohler et al., 2020). Además, la implementación de redes de memoria a corto y largo plazo (LSTM) ha mejorado la capacidad de los clasificadores para asociar experiencias previas y adaptarse a nuevos datos (Yang y Ding, 2020). Avances como modelos simétricos rotacionales y redes neuronales siamesas (SNN) han permitido especializar clasificadores para identificar patrones complejos, elevando la precisión en tareas específicas, Kohler y Walter (2022) corroboran dicha información, lo que coincide con Naihua et al., (2024).

Estos avances en la clasificación de imágenes mediante RN y nuevas metodologías de optimización presentan un potencial significativo para mejorar la comprensión del comportamiento del consumidor. Al clasificar con mayor precisión las preferencias y comportamientos de los estudiantes universitarios, es posible impactar directamente en las estrategias de marketing y desarrollo de productos dirigidos a este grupo (Hernández y Konig, 2019).

Dimensiones

X1: Arquitectura de la Red.

La elección del tipo de red neuronal, especialmente las redes neuronales convolucionales (CNN), es fundamental para la clasificación de imágenes. Las CNN son capaces de extraer características jerárquicas a partir de imágenes mediante la utilización de capas convolucionales y de pooling, lo que les permite identificar patrones visuales complejos de manera eficaz (Goodfellow, Bengio, y Courville, 2016).

X2: Características del conjunto de datos.

Esta dimensión abarca tanto el tamaño como la diversidad del conjunto de datos empleado para entrenar el modelo. Un conjunto de datos amplio y variado es crucial para mejorar la generalización del modelo y evitar el sobreajuste. Además, es importante considerar la calidad de las imágenes y la representación de las clases dentro del conjunto de datos (Li, Wu, y Zhang, 2023).

X3: Métricas de Evaluación.

Las métricas utilizadas para evaluar el rendimiento del modelo son esenciales para determinar su efectividad. Las métricas principales incluyen precisión, recall y F1-score, que son herramientas clave para medir la capacidad del modelo al clasificar imágenes en sus respectivas categorías (Schwarz y Lee, 2023).

Variable dependiente

Y: Comportamiento del consumidor universitario.

La experiencia del consumidor se refiere a la percepción general que un cliente tiene sobre una marca o producto después de interactuar con él. En el contexto universitario, esta experiencia abarca todos los aspectos de la interacción de los estudiantes con servicios, productos y recursos ofrecidos por la institución educativa. La calidad de esta experiencia puede influir significativamente en la satisfacción, lealtad y comportamiento futuro de los estudiantes (Rangel et al., 2021).

Factores que influyen en la experiencia del consumidor universitario

La experiencia del consumidor universitario está influenciada por diversos factores elementales:

Calidad de los servicios. En primer lugar, la calidad de los servicios desempeña un papel fundamental. La eficiencia y efectividad de los servicios administrativos, académicos y de soporte técnico son esenciales para garantizar la satisfacción del estudiante (Bustamante et al., 2022).

Ambiente de aprendizaje. Además, el ambiente de aprendizaje tiene una gran incidencia en la experiencia del estudiante. Un entorno que cuente con infraestructura adecuada, recursos educativos de calidad y un clima inclusivo contribuye de manera significativa a su satisfacción y desarrollo (Contreras et al., 2019).

Tecnología y acceso a la información. Finalmente, la tecnología y el acceso a la información son factores determinantes. La disponibilidad y facilidad de acceso a tecnologías avanzadas y recursos digitales enriquecen la experiencia educativa, facilitando tanto el aprendizaje como la investigación (Romero et al., 2016).

Dimensiones

Y1: Motivación del comportamiento del consumidor en estudiantes universitarios.

La motivación juega un papel fundamental en el comportamiento del consumidor, y en el caso de los estudiantes universitarios, está influenciada por una variedad de necesidades y deseos. Entre estos se incluyen la búsqueda de reconocimiento académico, el deseo de adquirir conocimiento y la mejora de habilidades tanto personales como profesionales. Desde la perspectiva de la Teoría de Maslow, la jerarquía de necesidades humanas puede aplicarse al contexto universitario, donde primero se deben satisfacer las necesidades básicas, como las fisiológicas y de seguridad, antes de que los estudiantes busquen cumplir con necesidades superiores, como el reconocimiento y la autorrealización. Además, la Teoría de la Autodeterminación destaca que los estudiantes están motivados por su necesidad de competencia, autonomía y relaciones sociales, factores que influyen de manera significativa en su impulso por alcanzar sus metas académicas y personales (Deci y Ryan, 2000). Por otro lado, los indicadores como motivación a compra, exploración de nuevos productos, intereses coincidentes, reutilización del sistema, interés de compra inmediata, Motivación del comportamiento del consumidor en estudiantes universitarios, percepción del comportamiento del consumidor en estudiantes universitarios. la percepción es el proceso a través del cual las personas seleccionan, organizan e interpretan la información para construir una visión coherente del entorno.

En el caso de los estudiantes universitarios, la forma en que perciben la calidad educativa, las condiciones de la infraestructura del campus y los servicios de apoyo afecta directamente sus decisiones y comportamientos de consumo. Según Kotler y Keller (2016), la percepción del consumidor es subjetiva y puede verse moldeada tanto por factores internos, como las experiencias previas y las expectativas, como por factores externos, tales como las estrategias de marketing y las opiniones de otros estudiantes.

Y3: Aprendizaje del comportamiento del consumidor en estudiantes universitarios.

El aprendizaje implica un cambio en el comportamiento del consumidor debido a la experiencia y la información adquirida. En el contexto universitario, los estudiantes aprenden no solo mediante la enseñanza formal en el aula, sino también a través de interacciones sociales y experiencias prácticas. La teoría del aprendizaje social de Bandura propone que los estudiantes adquieren conocimientos observando y copiando el comportamiento de sus compañeros y modelos a seguir. Además, el desarrollo de habilidades críticas, promoviendo la participación en actividades colaborativas y proyectos prácticos (Bruner, 1966). Por otro lado, tenemos los indicadores como el aprendizaje sobre nuevos productos, descubrimiento de categorías, enseñanza sobre productos, facilitación del aprendizaje, mejora del conocimiento general, y la actitud del comportamiento del consumidor en estudiantes universitarios.

La actitud se define como la disposición aprendida de un individuo para reaccionar de manera positiva o negativa ante un objeto, persona o situación. En el caso de los estudiantes universitarios, sus actitudes hacia la educación, los profesores y la institución influyen de manera significativa en su comportamiento como consumidores. La teoría de la acción razonada, propuesta por Fishbein y Ajzen, sostiene que las actitudes, junto con las normas subjetivas, afectan las intenciones de comportamiento, las cuales, a su vez, determinan las acciones reales. En el ámbito universitario, una actitud positiva hacia la educación puede fomentar un mayor compromiso y éxito académico y los indicadores como la actitud general, y la recomendación a otros, y la confianza en el sistema y el uso futuro.

Metodología

El estudio es de tipo aplicado y de alcance explicativo, orientado a resolver problemas y predecir resultados. Busca medir la percepción sobre la clasificación de imágenes mediante redes neuronales y su relación con el comportamiento del consumidor en estudiantes universitarios. Se clasifica como explicativo porque analiza y explica relaciones causales entre variables, e investiga cómo un clasificador de imágenes con Redes Neuronales Artificiales (RNA) influye en la experiencia educativa. El diseño preexperimental evalúa los efectos de este sistema en el aprendizaje, explorando su impacto en la satisfacción e interacción del usuario, lo cual está alineado con los estudios explicativos. Con respecto a la población, se refiere a los estudiantes de la UNFV que usan plataformas digitales, la cual está compuesta por 500 estudiantes en Lima Metropolitana. Para el modelo de clasificación de imágenes, se incluyeron 625 imágenes de entrenamiento y 205 de prueba. Por otro lado, se seleccionó un grupo de 50 estudiantes universitarios de la UNFV para los pretest y postest en un diseño preexperimental, siguiendo criterios específicos de investigación. La investigación utilizó técnicas de Deep Learning, específicamente el modelo VGG16, y encuestas para estudiar la experiencia del consumidor en

estudiantes universitarios. El modelo VGG16 se seleccionó por su eficacia comprobada en la clasificación de imágenes. Además, se aplicó un cuestionario diseñado siguiendo los lineamientos de Denscombe para recopilar datos cuantitativos sobre la satisfacción y usabilidad del sistema propuesto.

Resultados y discusión

Figura 1

Carga del modelo VGG16 preentrenada con capas de ajuste fino para clasificación de imágenes

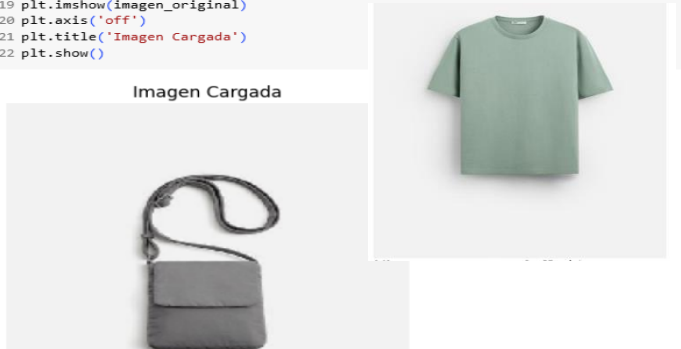
```
1 #Cargar el modelo
2 import tensorflow as tf
3 from tensorflow.keras.applications import VGG16
4 from tensorflow.keras import layers, models
5 from tensorflow.keras.preprocessing.image import ImageDataGenerator
6 from google.colab import drive
7 drive.mount('/content/drive')
8
9 # Definir la arquitectura del modelo
10 vgg16 = VGG16(weights='imagenet', include_top=False, input_shape=(224, 224, 3))
11
12 # Congelar las primeras capas
13 for layer in vgg16.layers[:15]:
14     layer.trainable = False
```

La imagen muestra el proceso de entrenamiento del modelo VGG16 durante 15 épocas. Se detallan las métricas de pérdida (loss) y precisión (accuracy) en los datos de entrenamiento.

Figura 2

Entrenamiento del modelo VGG16 en TensorFlow

```
1 #mostrar imagen
2 import numpy as np
3 from tensorflow.keras.preprocessing import image
4 import matplotlib.pyplot as plt
5
6 # Cargar y preprocesar la imagen
7 def cargar_y_preprocesar_imagen(ruta_imagen):
8     img = image.load_img(ruta_imagen, target_size=(224, 224))
9     img_array = image.img_to_array(img)
10    img_array = np.expand_dims(img_array, axis=0)
11    img_array /= 255.0
12    return img_array, img
13
14 # Ruta de la imagen
15 ruta_imagen = '/content/drive/MyDrive/data_set2/test/bolso/img_198.jpg'
16 imagen_preprocesada, imagen_original = cargar_y_preprocesar_imagen(ruta_imagen)
17
18 # Visualizar la imagen
19 plt.imshow(imagen_original)
20 plt.axis('off')
21 plt.title('Imagen Cargada')
22 plt.show()
```



En la Figura 2, la imagen presenta el código para cargar y probar el modelo VGG16 en TensorFlow. Se define su arquitectura, congelando las capas iniciales y añadiendo nuevas capas de clasificación para un conjunto de datos específico. También se verifica la construcción del modelo y se cargan los pesos entrenados, asegurando dimensiones adecuadas.

Figura 3

Interfaz de clasificador de imágenes con predicciones de alta confianza



En la figura 3 la imagen muestra una aplicación web de un clasificador de imágenes que permite al usuario seleccionar y cargar archivos de imagen. Dos ejemplos presentan resultados de clasificación: uno predice "calzado" con una confianza de 99.99%, y otro predice "polo" con un nivel de confianza de 99.99%. Ambas predicciones indican que el modelo tiene un alto grado de precisión en sus clasificaciones.

A continuación, se muestran los resultados descriptivos de la variable experiencia del consumidor:

Tabla 1

Nivel de experiencia del consumidor

Nivel	Pretest VD (%)	Postest VD (%)
Bueno	0%	90%
Regular	24%	10%
Malo	76%	0%

En el pretest, donde se evaluó el sistema tradicional sin el clasificador de imágenes, el 76% de los usuarios calificó su experiencia como Mala, y el 24% como "Regular", lo que reflejó una percepción mayormente negativa y una baja satisfacción con el sistema. Sin embargo, en el postest, después de la implementación del clasificador de imágenes, el 90% de los usuarios calificó su experiencia como "Buena", mientras que solo un 10% la consideró "Regular", y no se registraron calificaciones negativas.

Tabla 2

Rangos con signo de Wilcoxon del comportamiento del consumidor entre estudiantes universitarios

Hipótesis nula	Prueba	Sig.a,b	Decisión
La mediana de diferencias entre Experiencia del Consumidor - Pretest y Experiencia del Consumidor - Postest es igual a 0.	Prueba de rangos con signo de Wilcoxon para muestras relacionadas	,000	Rechazo de la hipótesis nula.

Nota. A. El nivel de significación es de ,050. B. Se muestra la significancia asintótica.

Se aplicó la prueba de rangos con signo de Wilcoxon para evaluar las diferencias en el comportamiento del consumidor antes y después de utilizar el clasificador de imágenes, obteniendo un valor de significancia de 0.000, que es inferior a 0.050. Esto llevó al rechazo de la hipótesis nula (H0), evidenciando que el clasificador de imágenes basado en redes neuronales mejora el comportamiento del consumidor entre estudiantes universitarios.

La diferencia observada no es aleatoria, sino un cambio real en la interacción y decisiones de los consumidores tras la aplicación del clasificador.

En cuanto a la discusión de resultados, podemos señalar en relación con el objetivo general de esta investigación, que fue determinar cómo el clasificador de imágenes basado en redes neuronales (RN) mejora el comportamiento del consumidor en estudiantes universitarios, los resultados obtenidos indican un efecto significativo. La prueba de rangos de Wilcoxon arrojó un valor de significancia de 0.000, lo que confirma que el cambio observado no es aleatorio, sino que es atribuible directamente a la intervención tecnológica. Este hallazgo respalda los resultados de Briones (2020), quien subrayó la importancia de la experiencia del cliente en la satisfacción, aunque centró su investigación en centros comerciales, este estudio amplía esta perspectiva al contexto de decisiones de consumo de los estudiantes universitarios, específicamente en la interacción con una tecnología de clasificación de imágenes.

Finalmente, el uso de redes neuronales densas y convolucionales (VGG16) mostró una alta precisión en la clasificación de imágenes, destacándose el uso de técnicas como la normalización, el aumento de datos y el análisis visual. Estos resultados son consistentes con los encontrados por Alipour (2024), quien probó CNNs con datos de diversas fuentes y resaltaron la importancia de seleccionar adecuadamente las características de los datos. La alta precisión alcanzada en nuestro modelo de RN refuerza la validez de estos hallazgos, destacando la clasificación precisa como un factor trascendente para mejorar la confianza en el modelo y, por ende, la experiencia del consumidor en plataformas digitales.

Conclusiones

En cuanto a la aplicación del modelo de clasificador de imágenes basado en Redes Neuronales Convolucionales (RNC) para un retail, se utilizó la arquitectura preentrenada VGG16 como base. Esta configuración permitió aprovechar características avanzadas en el procesamiento de imágenes, mejorando significativamente el rendimiento del modelo. Además, se aplicaron técnicas de aumento de datos, como rotación, desplazamiento y zoom, para optimizar la capacidad del modelo para generalizar y adaptarse a las variaciones de las imágenes. El modelo, entrenado con 625 imágenes de cuatro categorías de productos (bolsos, calzado, pantalones y polos), alcanzó una alta precisión en las predicciones, deteniéndose automáticamente al alcanzar la mejor precisión posible. En la fase de prueba, el modelo clasificó nuevas imágenes de productos con un alto nivel de confianza, lo que permitió sugerir etiquetas específicas para cada categoría de productos de retail.

La prueba de rangos con signo de Wilcoxon arrojó un valor de significancia de 0,000, lo que llevó al rechazo de la hipótesis nula. Esto demuestra que los cambios observados en la motivación, percepción, aprendizaje y actitud de los estudiantes no fueron aleatorios, sino que se atribuyen de manera directa a la implementación del clasificador de imágenes. Se utilizó la arquitectura VGG16 preentrenada de redes neuronales convolucionales, aplicando técnicas de aumento de datos para mejorar el rendimiento del modelo. El modelo alcanzó alta precisión en la clasificación de cuatro categorías de productos, demostrando ser efectivo para sugerir etiquetas en un contexto de retail.

Referencias

- Akbiyik, M. (2019). Data Augmentation in Training CNNs: Injecting Noise to Images. *arXiv*. <https://www.semanticscholar.org/paper/Data-Augmentation-in-Training-CNNs:-Injecting-Noise-Akbiyik/25945081386bb3d56379bf7896829a56017fb34d>
- Artola, A. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*. [Tesis de Pregrado, Universidad de Sevilla]. <https://idus.us.es/items/5de63781-526e-4cb1-94c1-a70431bfb9d4>
- Bennett, N., y Lemoine, G. J. (2019). *What a difference a word makes: Understanding threats to performance in a VUCA world*. *Business Horizons*, 62(3), 273–283. <https://doi.org/10.1016/j.bushor.2019.01.008>
- Briones, H. (2020). *Relación entre la experiencia del consumidor y la satisfacción del cliente de un centro comercial en la ciudad de Cajamarca* [Tesis de Pregrado, Universidad Privada del Norte]. <https://repositorio.upn.edu.pe/handle/11537/24264?show=full>
- Bruner, J. S. (1966). *Toward a theory of instruction*. Harvard University Press. <https://www.hup.harvard.edu/books/9780674897014>
- Bustamante, H., Sánchez, N., Agudelo, J. y Camilo, M. (2022). Tendencias de consumo de los estudiantes universitarios y la influencia del e-commerce durante la Pandemia del COVID-19: Estudio de caso. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, 3(2), 355-371. <https://doi.org/10.56712/latam.v3i2.92>

- Contreras, M., Rojano, Y. y Cardona, D. (2019). Caracterización del consumidor universitario: un estudio etnográfico. *Panorama Económico*, 27(2), 559-574. <https://dialnet.unirioja.es/servlet/articulo?codigo=7513401>
- Davenport, T. H., y Ronanki, R. (2018). *Artificial intelligence for the real world*. *Harvard Business Review*, 96(1), 108–116. <https://hbr.org/2018/01/artificial-intelligence-for-the-real-world>
- Deci, E., y Ryan, R. (2009). The "What" and "Why" of Goal Pursuits: Human Needs and the Self-Determination of Behavior. *Psychological Inquiry*, 11(4), 227-268. https://doi.org/10.1207/S15327965PLI1104_01
- Ferreira, I. (2021). *Estudio de las experiencias del consumidor con tecnologías inteligentes controladas por voz*. [Tesis de Doctorado, Universidad de la Rioja]. <https://dialnet.unirioja.es/servlet/tesis?codigo=304874>
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org/>
- Hafiz, R., y Bhat, G. (2020). Deep Network Ensemble Learning applied to Image Classification using CNN Trees. *Journal of Computer Vision*, 22(2), 1-9. <https://arxiv.org/pdf/2008.00829>
- Hernández, R., Fernández, C. y Baptista, M. (2014). *Metodología de la Investigación (6ta ed.)*. McGraw-Hill. <https://dialnet.unirioja.es/servlet/libro?codigo=775008>
- Hernández-García, A. y Konig, P. (2029). Further advantages of data augmentation on convolutional neural networks. *arXiv*. 1-8. <https://arxiv.org/pdf/1906.11052>
- Hurwitz, J., y Kirsch, D. (2018). *Machine learning for dummies (2nd ed.)*. Wiley. <https://doi.org/10.1002/9781119473721>
- Kohler, M., Krzyzak, A., y Walter, G. (2020). On the rate of convergence of image classifiers based on convolutional neural networks. *Annals of the Institute of Statistical Mathematics*, 74, 1085-1108. <https://link.springer.com/article/10.1007/s10463-022-00828-4>
- Kohler, M., y Walter, G. (2022). Analysis of Convolutional Neural Network Image Classifiers in a Rotationally Symmetric Model. *IEEE Transactions on Information Theory*, 69(8), 5203-5218. <https://ieeexplore.ieee.org/document/10083208>
- Kotler, P., y Keller, K. (2016). *Marketing Management (15 ed.)*. Pearson. https://www.academia.edu/37145555/Direcci%C3%B3n_en_Marketing_Kotler_y_Keller_15va_edici%C3%B3n
- Kumar, A., Singh, K. P., Kumar, S., y Vetrivendan, L. (2022). Image classification in Python using Keras. En D. Gupta, Z. Polkowski, A. Khanna, S. Bhattacharyya, y O. Castillo (Eds.), *Proceedings of Data Analytics and Management*. Springer, 90, 557–564. https://doi.org/10.1007/978-981-16-6289-8_45
- Li, Q., Huang, Z., Yang, H. y Song, M. (setiembre de 2023). *A review of quantum machine learning for image classification*. En 2023 2nd International Conference on Artificial Intelligence, Internet of Things and Cloud Computing Technology, IEEE, 70-75. <https://doi.org/10.1109/IMSE61332.2023.00021>
- Naihua, J., Rongyi, B., Zhao, C., Yiming, Y. y Hongyang, M. (2024). Hybrid Quantum Neural Network Image Anti-Noise Classification Model Combined with Error Mitigation. *Applied Sciences*, 14(4), 1392. <https://doi.org/10.3390/app14041392>
- Rangel, L., Azuela, J. y Ochoa, M., (2020). Explorando el perfil del consumidor universitario. Un estudio de caso de una escuela socialmente responsable en México. *CIENCIA ergo-sum, Revista Científica Multidisciplinaria de Prospectiva*, 28(3). <https://www.redalyc.org/journal/104/10467404008/html/>
- Romero, F., Carrió, M. y Yang, Q. (2016). *Hábitos de consumo TIC de los estudiantes universitarios estudio comparativo entre China y España*. Universitat d'Alacant. <https://rua.ua.es/dspace/handle/10045/64942>
- Schwarz, D., Lee, J., y Xu, Y. (2023). Performance evaluation metrics for deep learning models in medical image classification: A comprehensive review. *Journal of Medical Imaging and Health Informatics*, 13(4), 915-927. <https://doi.org/10.1166/jmihi.2023.432>
- Yang, H., y Ding, Y. (2020). Associative Memory Optimized Method on Deep Neural Networks For Image Classification. *Information Sciences*, 533, 108-119. <https://doi.org/10.1016/j.ins.2020.05.038>