



fecha de presentación: 10/07/2025, fecha de aceptación: 09/08/2025, fecha de publicación: 01/09/2025

Kleber Francisco Franco-Santacruz
Email: kffranco_est@utmachala.edu.ec
Orcid: <https://orcid.org/0009-0001-7359-3463>

Bill Jonathan Serrano-Orellana
Email: bjserrano@utmachala.edu.ec
Orcid: <https://orcid.org/0000-0002-9101-4541>

Universidad Técnica de Machala, Facultad de Ciencias Empresariales. Machala, Ecuador

Cita sugerida (APA, séptima edición)

Franco-Santacruz, K. F., & Serrano-Orellana, B. J. (2025). Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning. *Revista Sociedad & Tecnología*, 8(S2), 327-341. DOI: <https://doi.org/10.51247/st.v8iS2.647>.

==== O ====

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

RESUMEN

Este estudio examina el potencial del *machine learning* para predecir el comportamiento de compra en entornos de retail físico, integrando variables emocionales y factores contextuales. A través de una revisión bibliográfica de literatura académica reciente, se analizan modelos predictivos que trascienden las variables demográficas tradicionales e incorporan dimensiones afectivas como estados emocionales, y contextuales como la hora del día o la ubicación en tienda. Se reconoce que, aunque el comercio electrónico ha avanzado en el uso de tecnologías predictivas, el retail presencial aún enfrenta limitaciones en la recolección de datos significativos. El análisis revela tanto el valor estratégico de estos sistemas para optimizar la experiencia del consumidor como los dilemas éticos emergentes relacionados con la manipulación emocional y el uso intensivo de datos. Los hallazgos contribuyen a la comprensión del consumidor como un sujeto complejo y permiten sentar bases conceptuales para futuras investigaciones y prácticas en marketing sensorial y predictivo aplicado a espacios físicos.

Palabras Clave: Machine Learning, retail físico, estados emocionales, factores contextuales.

==== O ====

Purchase prediction based on emotional states and contextual factors in retail physical using Machine Learning

ABSTRACT

This study examines the potential of machine learning to predict shopping behavior in physical retail environments, integrating emotional variables and contextual factors. Through a literature review of recent academic literature, predictive models that transcend traditional demographic variables and incorporate affective dimensions such as emotional

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

states, and contextual dimensions such as time of day or store location, are analyzed. It is recognized that while e-commerce has advanced in the use of predictive technologies, face-to-face retailing still faces limitations in collecting meaningful data. The analysis reveals both the strategic value of these systems in optimizing the consumer experience and the emerging ethical dilemmas related to emotional manipulation and intensive use of data. The findings contribute to the understanding of the consumer as a complex subject and provide a conceptual foundation for future research and practice in sensory and predictive marketing applied to physical spaces.

Keywords: Machine Learning, physical retail, emotional states, contextual factors.

==== O ====

Previsão de Compra Baseada em Estados Emocionais e Fatores Contextuais no Retalho Físico Utilizando Machine Learning

RESUMO

Este estudo examina o potencial da aprendizagem automática para prever o comportamento de compra em ambientes de retalho físico, integrando variáveis emocionais e fatores contextuais. Através de uma revisão bibliográfica da literatura académica recente, são analisados modelos preditivos que transcendem as variáveis demográficas tradicionais e incorporam dimensões afetivas, como estados emocionais, e fatores contextuais, como a hora do dia ou a localização da loja. Reconhece-se que, embora o comércio eletrónico tenha avançado na utilização de tecnologias preditivas, o retalho físico ainda enfrenta limitações na recolha de dados significativos. A análise revela tanto o valor estratégico destes sistemas na otimização da experiência do consumidor como os dilemas éticos emergentes relacionados com a manipulação emocional e a utilização intensiva de dados. Os resultados contribuem para a compreensão do consumidor como um sujeito complexo e estabelecem as bases conceptuais para futuras pesquisas e práticas em marketing sensorial e preditivo aplicado a espaços físicos.

Palavras-chave: Machine Learning, retalho físico, estados emocionais, fatores contextuais.

==== O ====

INTRODUCCIÓN

Desde la aparición de plataformas como Amazon y eBay en la década de 1990, el comercio electrónico ha experimentado un crecimiento sostenido, acelerándose exponencialmente en los últimos años. Este auge ha llevado a que las tiendas minoristas dirijan su atención al entorno digital. Dado el impacto comprobado que ejercen las "señales del ambiente" o la atmósfera en los espacios físicos sobre el comportamiento del consumidor, ha surgido un creciente interés por analizar si dichos principios también influyen en la experiencia de compra en línea (Csoban-Mirka et al., 2024).

En el cambiante entorno del comercio minorista, las tiendas físicas enfrentan crecientes desafíos para entender el comportamiento de sus clientes, en especial frente al avance del comercio electrónico que ha incorporado herramientas tecnológicas avanzadas para rastrear y predecir las decisiones de consumo. A diferencia del e-commerce, donde cada clic puede traducirse en datos valiosos, el retail presencial presenta limitaciones sustanciales en la recolección y análisis de información que permita anticipar la conducta del consumidor (Mannino, 2021). Esta desventaja ha generado una creciente necesidad de incorporar tecnologías emergentes que ayuden a cerrar dicha brecha y ofrezcan ventajas competitivas sostenibles.

Entre los múltiples factores que inciden en la decisión de compra, las emociones del consumidor se han posicionado como un elemento clave en diversos estudios de psicología del consumo, particularmente en contextos de compras hedónicas o impulsivas. No obstante, su integración en sistemas de análisis en el entorno físico sigue siendo limitada, tanto a nivel teórico como aplicado. La ausencia de modelos predictivos capaces de incorporar simultáneamente las emociones del cliente y factores contextuales, como la hora del día, el clima o la ubicación dentro de la tienda, representa un vacío que este estudio busca abordar.

En este marco, la inteligencia artificial, y más concretamente el machine learning, emerge como una herramienta con alto potencial para transformar la experiencia en tiendas físicas mediante sistemas inteligentes de apoyo a la toma de decisiones (Morales y Pérez, 2021). La capacidad de estas tecnologías para detectar patrones complejos permite desarrollar modelos predictivos que trascienden las variables tradicionales (como edad o historial de compra) e incorporan dimensiones emocionales y contextuales que hasta ahora han sido poco exploradas.

Por ello, el presente estudio tiene como finalidad analizar el potencial de los modelos de machine learning para predecir el comportamiento de compra en entornos de retail físico, considerando la incorporación de estados emocionales y factores contextuales. Dado que la literatura académica reconoce la influencia significativa de las emociones y del contexto en la toma de decisiones del consumidor, esta investigación busca sistematizar el conocimiento existente y evaluar sus implicaciones teóricas y prácticas en el ámbito del comercio presencial.

Así mismo, la revisión permitirá identificar las variables emocionales y contextuales más relevantes según estudios previos, así como los enfoques metodológicos más utilizados para integrarlas en sistemas predictivos. Se plantea que los resultados obtenidos sirvan como base conceptual para futuras investigaciones aplicadas y para la formulación de estrategias innovadoras en el diseño de experiencias de compra más inteligentes, empáticas y eficaces dentro del retail físico.

REVISIÓN DE LA LITERATURA

En el comercio minorista según Alves et al. (2021), la cantidad de ventas es uno de los principales indicadores que pueden informar sobre la salud de la empresa, por lo tanto, generar previsiones de ventas es una buena herramienta que puede ayudar al gestor en la dirección del negocio (Zunic et al. 2020). Cuando esta tienda se encuentra en Internet como comercio electrónico, se pueden recoger diversas métricas en relación con el comportamiento del cliente y las ventas, por ejemplo: tiempo de visualización de un producto, número de clics, artículos en el carrito, número de ventas, tiempo medio de venta y otros (Shaytura et al., 2017).

En el contexto del comercio minorista físico, la adopción de técnicas de aprendizaje automático (ML), especialmente del aprendizaje profundo, ha generado transformaciones significativas en el procesamiento de imágenes aplicado a entornos comerciales. Estos avances se deben, en gran medida, a la evolución de las arquitecturas de redes neuronales, en particular las redes neuronales convolucionales (CNN), las cuales permiten la extracción automatizada de atributos relevantes a partir de datos visuales sin procesar (Ojika et al., 2022).

Esto reduce considerablemente la dependencia de características diseñadas manualmente, optimizando así procesos como el reconocimiento de productos, el análisis del comportamiento del consumidor y la gestión operativa en puntos de venta (Collins et al., 2022; Nguyen y Biderman, 2008; Zhou, 2021).

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

La irrupción de Internet ha transformado profundamente el comercio, modificando los procesos mediante los cuales los consumidores buscan, comparan, adquieren y utilizan productos y servicios (Peciña, 2017). En los últimos años, el número de compradores en línea ha experimentado un incremento significativo; entre 2022 y 2023, se registró un aumento de 80 millones de usuarios, lo que representa una tasa de crecimiento anual del 3,1 %.

En las últimas décadas, numerosos investigadores han abordado interrogantes relacionadas con las variables ambientales que influyen en los estados emocionales de los consumidores, el impacto de estos factores en el comportamiento de compra posterior, y las estrategias que deben implementar las empresas para diseñar experiencias multisensoriales en tienda que favorezcan la conversión y aseguren un retorno sobre la inversión (Spence, 2022).

Autores como Zaltman (2004) plantea que el consumidor es un agente altamente complejo y juega un papel crucial en el proceso de mercadeo. En este contexto, introduce el concepto de "inconsciente cognitivo del consumidor", el cual hace referencia al conjunto de conocimientos implícitos que influyen en la conducta de compra, más allá de lo que el individuo puede expresar de forma consciente.

Los aspectos emocionales y sensoriales que favorecen la creación de vínculos son fundamentales para atraer a los consumidores (Hultén, 2011; Ortegón-Cortázar y Gómez, 2016). El objetivo del marketing es generar productos capaces de evocar sensaciones, emociones y respuestas cognitivas, propiciando experiencias que integren tanto lo físico como lo mental. En este sentido, dichos elementos son incorporados estratégicamente en las prácticas de marketing con el fin de influir en la percepción del consumidor (Tinoco-Egas et al., 2019).

Según Čosić (2015), las emociones desempeñan un rol esencial, ya que constituyen respuestas instintivas que pueden manifestarse incluso antes del desarrollo de la conciencia. Estas respuestas influyen significativamente en el comportamiento y en la manera en que las personas perciben su entorno, afectando también su capacidad para experimentar recompensas (Dailey, 2012). En este sentido, las emociones potencian la sensación de placer asociada al acto de compra.

Este enfoque se complementa con la perspectiva de Goleman (2012), quien sostiene que la inteligencia emocional representa una forma de interacción con el mundo basada en el reconocimiento y la gestión de las emociones. Este tipo de inteligencia abarca competencias como el control de los impulsos, la autoconciencia, la motivación, el entusiasmo, la empatía y la capacidad cognitiva para afrontar y resolver problemas de manera efectiva.

Según Hawkins et al. (2004), estas surgen a partir de estímulos del entorno, los cuales, mediante procesos mentales, desencadenan respuestas fisiológicas como el aumento de la transpiración, la dilatación pupilar, la aceleración del ritmo cardíaco y respiratorio, así como un incremento en los niveles de glucosa en sangre. Estos cambios fisiológicos influyen significativamente en el pensamiento y en el comportamiento del consumidor.

El concepto de *Big Data* se refiere a la acumulación de volúmenes de datos tan extensos que exceden la capacidad de las herramientas tradicionales para ser capturados, gestionados y procesados de manera eficiente en un tiempo razonable (Durán, 2017). Un conjunto de datos se clasifica como *Big Data* cuando su tamaño y complejidad requieren la intervención de analistas especializados, ya que no puede ser manejado adecuadamente mediante los programas de software convencionales de uso general (López Mateus, 2020).

El aprendizaje automático, o *machine learning*, es una subdisciplina de la inteligencia artificial (IA) que capacita a los sistemas para aprender a partir de datos, sin requerir una programación explícita para cada tarea (Rojas Paucar, 2024). Mediante el uso de algoritmos y modelos estadísticos, esta tecnología identifica patrones en los datos con el fin de generar

predicciones o tomar decisiones de forma automatizada (Lasso Vivas, 2024). Su aplicación resulta especialmente valiosa en el sector *retail*, donde las empresas gestionan grandes volúmenes de información provenientes de múltiples fuentes, como ventas en línea, tiendas físicas e interacciones en redes sociales (Durán, 2017).

Autores como Zaltman (2004) y Ćosić (2015) son utilizados para sustentar la idea de que las decisiones de compra están determinadas por procesos automáticos y afectivos, más que por una reflexión racional. Sin embargo, esta concepción reduce al consumidor a un objeto de manipulación, susceptible de ser condicionado mediante técnicas de marketing experiencial, sin cuestionar las implicaciones de esta instrumentalización de las emociones. Se ignora, además, la agencia del consumidor como sujeto reflexivo y crítico, capaz de resistir o reinterpretar los estímulos comerciales desde su propio marco de valores y contextos socioculturales.

Del mismo modo, el entusiasmo por la incorporación de tecnologías como el Big Data y el aprendizaje automático revela una postura tecnófila que asume, sin mayor cuestionamiento, que estos avances necesariamente optimizan los procesos de mercado y benefician tanto a empresas como a consumidores. No obstante, el uso intensivo de datos personales en el entorno digital plantea serios dilemas en torno a la privacidad, la vigilancia algorítmica y el sesgo automatizado, aspectos que el texto omite por completo. Resulta problemático asumir que una mayor capacidad de predicción y segmentación siempre se traduce en experiencias más satisfactorias para el consumidor, sin considerar que estos sistemas pueden reforzar patrones de exclusión, homogeneización de gustos y explotación emocional.

La referencia a la inteligencia emocional como herramienta para la gestión efectiva de los consumidores es posible interpretarla como una estrategia empresarial que instrumentaliza las emociones con fines comerciales. Goleman (2012) es citado para destacar las competencias emocionales que deben desarrollarse en contextos de consumo, pero no se cuestiona cómo esta noción ha sido cooptada por el discurso corporativo para justificar prácticas de control afectivo en entornos laborales y de mercado. En este sentido, se pierde la oportunidad de discutir el carácter político de la emoción en las relaciones de consumo y la necesidad de una ética del marketing que respete la autonomía del sujeto.

METODOLOGÍA

Se llevó a cabo un estudio cuantitativo y no experimental, con un diseño transversal y de tipo correlacional-predictivo, siguiendo la metodología propuesta por Espinoza (2020a). El objetivo fue examinar la relación entre las emociones, los factores contextuales y la decisión de compra en tiendas físicas, sin manipular las variables.

La investigación tuvo un enfoque cuantitativo, ya que se basó en la recolección y el análisis de datos numéricos para identificar patrones y relaciones estadísticas entre variables. El diseño metodológico fue no experimental, transversal y correlacional-predictivo, según la referencia de Burgo Bencomo (2019). El estudio tuvo una orientación aplicada, buscando generar conocimiento útil para crear herramientas predictivas que mejoraran la experiencia del cliente y las estrategias de marketing.

La población objetivo estuvo conformada por consumidores de tiendas de retail físico en la ciudad de Machala. Se seleccionó una muestra no probabilística de 300 individuos, utilizando un muestreo por conveniencia debido a la accesibilidad y disponibilidad de los participantes. Esto difiere de la estimación inicial de 180 individuos. Los participantes fueron invitados a colaborar voluntariamente después de su experiencia de compra.

Para la recolección de datos, se usó un cuestionario estructurado que incluyó las siguientes secciones:

- Datos sociodemográficos: edad, género, nivel educativo y frecuencia de visitas.

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

- Estados emocionales: Se evaluaron usando el modelo Self-Assessment Manikin (SAM), que mide la valencia, activación y dominancia en una escala visual tipo Likert.
- Factores contextuales: Se registraron variables como la hora del día, el ruido, la limpieza, la presencia de promociones, la interacción con el personal y la organización del espacio.
- Resultado de la visita: Se documentó si se concretó una compra y sus características (tipo de producto, valor, impulsividad, etc.).

La aplicación de la encuesta se realizó de forma presencial y a través de dispositivos móviles, garantizando la confidencialidad y el consentimiento informado de los participantes.

Los datos recolectados se procesaron y analizaron con herramientas estadísticas y de programación. Se utilizó el lenguaje Python y bibliotecas especializadas como pandas, numpy, scikit-learn y matplotlib. Este enfoque permitió construir modelos predictivos, a través de técnicas de *machine learning*, para anticipar la probabilidad de que un consumidor realizara una compra, a partir de la información emocional y ambiental (Espinoza, 2020b).

RESULTADOS Y DISCUSIÓN

Durante la investigación llevada a cabo se contó con una muestra de 300 consumidores, quienes participaron voluntariamente tras su experiencia en establecimientos de retail físico. A continuación, se detalla la caracterización sociodemográfica de los participantes, así como los principales resultados obtenidos en relación con las variables emocionales y contextuales medidas.

Características sociodemográficas

En cuanto al género, la distribución se compuso de un 37,3% de participantes femeninos, 34,3% masculinos, y 28,3% que prefirieron no responder. En relación al nivel educativo, el 22,3% reportó haber cursado educación secundaria, seguido por el 21% con formación de posgrado, 19,3% con estudios superiores técnicos o universitarios, 19% que no respondieron, y 18,3% con educación primaria.

Estados emocionales percibidos

Los estados emocionales de los participantes fueron medidos mediante el modelo Self-Assessment Manikin (SAM), el cual evalúa tres dimensiones afectivas: valencia, activación y dominancia. En la dimensión de valencia, la media fue de 3,00 (DE = 1,48), lo que sugiere experiencias levemente agradables durante la visita. En cuanto a la activación (arousal), el promedio fue de 2,63 (DE = 1,21), reflejando un nivel moderado-bajo de excitación emocional.

Factores contextuales del entorno de compra

En lo que respecta a los factores ambientales, los datos revelan que la mayoría de las visitas ocurrieron en horario matutino (08:00 a 12:00) con un 34%, seguido por la noche (17:01 a 21:00) con un 33,7%, y la tarde (12:01 a 17:00) con un 32,3%. La percepción de concurrencia fue predominantemente "moderada" (34%), aunque un 33,7% indicó que había pocos clientes y un 32,3% percibió el entorno como muy lleno.

En cuanto al ruido ambiental, los participantes asignaron una media de 2,65 (DE = 1,33) en una escala de 1 a 5. La variable "promociones en tienda" estuvo ausente en el 59% de los casos, mientras que el 41% de los encuestados reportó haber observado algún tipo de promoción.

Decisión de compra

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

En términos del comportamiento final, se observó que el 47% de los participantes realizaron una compra, mientras que el 53% no concretó ninguna adquisición durante su visita. Esta distribución equilibrada permite explorar con robustez las relaciones entre los distintos factores analizados y la conducta de compra.

Análisis de correlación

Con el objetivo de identificar posibles asociaciones entre las variables independientes (emocionales, contextuales y sociodemográficas) y la decisión de compra, se emplearon dos tipos de análisis estadístico: la prueba de chi-cuadrado de independencia para variables categóricas, y la correlación de Spearman para variables numéricas u ordinales.

Asociación entre variables categóricas y decisión de compra

Se aplicaron pruebas de chi-cuadrado a un conjunto de variables cualitativas, tales como género, nivel educativo, frecuencia de visitas, hora de visita, percepción de concurrencia, promociones y la interacción con el personal. Los resultados permitieron identificar asociaciones estadísticamente significativas entre algunas de estas variables y la decisión de compra ($p < .05$), lo cual sugiere que ciertos aspectos contextuales o demográficos podrían influir de forma diferencial en el comportamiento de consumo.

Asociación entre variables numéricas y decisión de compra

Las correlaciones no paramétricas de Spearman se calcularon entre la variable binaria de compra (sí = 1, no = 0) y las dimensiones numéricas: valencia, activación, dominancia, ruido y limpieza/organización. Los resultados mostraron coeficientes bajos y no significativos ($p > .05$) en todos los casos, indicando que, de forma aislada, estas variables no se relacionan de manera lineal o monótona con la conducta de compra.

Tabla 1. Correlaciones de variables mediante el coeficiente de Spearman

Variable	Coeficiente de Spearman (ρ) p-valor	
Valencia (agradable)	0.023	0.689
Arousal (activación)	0.042	0.468
Dominancia (control)	0.028	0.631
Ruido	-0.085	0.144
Limpieza/organización	-0.034	0.557

Aunque estos resultados podrían parecer poco concluyentes desde una perspectiva correlacional simple, se plantea que las emociones y factores ambientales pueden interactuar de forma más compleja en modelos predictivos multivariables, donde pueden adquirir mayor relevancia al combinarse con otras dimensiones del contexto.

Modelos predictivos y métricas de desempeño

Con el fin de evaluar la capacidad de predicción de las variables emocionales y contextuales sobre la decisión de compra, se desarrollaron y compararon dos modelos de machine learning: regresión logística y random forest. Ambos fueron entrenados utilizando el 70% de los datos y validados sobre el 30% restante del conjunto muestral. Esta estrategia permitió evaluar el desempeño predictivo de manera objetiva, minimizando riesgos de sobreajuste.

Regresión logística

La regresión logística es un modelo lineal ampliamente empleado en clasificación binaria, que permite estimar la probabilidad de ocurrencia de un evento (en este caso, realizar o no una compra). Los resultados obtenidos indicaron un accuracy del 55,6%, una precisión del 65,8%, un recall del 48,1%, y una puntuación F1 de 55,6%. El valor del área bajo la curva

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

ROC (AUC) fue de 0.59, lo que refleja una capacidad predictiva moderadamente superior al azar.

Random Forest

El modelo de random forest, basado en un ensamble de múltiples árboles de decisión, permite capturar relaciones no lineales y complejas entre variables. Sin embargo, en este estudio, su desempeño fue inferior al de la regresión logística, alcanzando un accuracy del 45,6 %, precisión del 55,6 %, recall de 28,8 %, F1-score de 37,9 %, y un AUC de 0.48, lo que sugiere una capacidad de discriminación por debajo del umbral esperado.

Comparación de resultados

La comparación entre ambos modelos se resume en la siguiente tabla:

Tabla 2. Comparación de resultados

Modelo	Accuracy	Precisión	Recall	F1-score	AUC
Regresión logística	55,6 %	65,8 %	48,1 %	55,6 %	0.59
Random Forest	45,6 %	55,6 %	28,8 %	37,9 %	0.48

El modelo de regresión logística mostró un desempeño superior en todas las métricas frente al modelo de random forest, aunque en términos generales, los valores de predicción fueron moderados a bajos. Esto sugiere que si bien existe cierto poder predictivo en las variables consideradas, la decisión de compra parece depender también de factores no capturados en el modelo actual.

Importancia de variables predictoras

Para comprender la contribución específica de cada variable en la predicción de la conducta de compra, se analizó la importancia relativa de las características dentro del modelo de random forest, dado que este tipo de algoritmo permite identificar de manera robusta el peso individual de cada predictor en la clasificación.




Figura 1. Importancia de variables predictoras (Random Forest)

Variables más influyentes

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

El análisis de importancia reveló que los factores emocionales y demográficos jugaron un papel destacado en la predicción. Las cinco variables con mayor influencia fueron:

1. **Arousal (activación emocional)** – 9,85 %
2. **Valencia (agradabilidad)** – 9,61 %
3. **Edad** – 9,47 %
4. **Limpieza y organización percibida** – 8,78 %
5. **Nivel educativo** – 8,63 %

Este hallazgo es relevante, ya que indica que las emociones percibidas durante la experiencia de compra, en especial el nivel de activación, así como la percepción del ambiente físico y las características del consumidor, pueden incidir en la propensión a realizar una compra.

Variables con menor peso predictivo

En contraste, otras variables contextuales tradicionales mostraron menor influencia en la predicción:

- **Promociones visibles en tienda** – 4,43 %
- **Interacción con el personal de ventas** – 4,11 %
- **Hora del día en que se realizó la visita** – 6,52 %

Estos resultados son importantes dado que contradicen cierta intuición previa respecto a la importancia directa de elementos promocionales o del contacto humano en el proceso de decisión. Se plantea la hipótesis de que estos factores podrían tener un efecto mediado o moderado por otros elementos emocionales o situacionales más complejos.

DISCUSIÓN

La pregunta central que orientó este estudio fue: ¿en qué medida los estados emocionales y factores contextuales pueden predecir la decisión de compra en entornos de retail físico? Los resultados indican que, aunque estos elementos tienen cierta capacidad predictiva, esta es moderada, y su eficacia aumenta al ser integrados en modelos multivariados.

Si bien el análisis correlacional no halló una asociación significativa entre emociones y compra, el modelo de random forest reveló que la activación emocional y la valencia fueron dos de los predictores más influyentes. Este hallazgo se alinea con investigaciones previas que sugieren que las emociones actúan más como moderadores complejos del comportamiento que como predictores directos (Ladhari et al., 2017; Puccinelli et al., 2009).

Según lo expuesto por International Business Machines (IBM, 2023), este enfoque promueve una toma de decisiones asertiva dentro del ecosistema de aplicaciones y procesos empresariales, debido a su incidencia directa en indicadores clave de desempeño. En esta misma línea, Janiesch et al. (2021) afirman que el aprendizaje automático (ML) permite prescindir de la necesidad de que los seres humanos expliciten y formalicen su conocimiento en formatos comprensibles para las máquinas, lo cual facilita el desarrollo más eficiente de sistemas inteligentes.

La activación, en particular, parece vincularse con una mayor disposición a actuar (como comprar), coincidiendo con los planteamientos de Russell (1980) sobre la importancia del arousal en la toma de decisiones impulsivas. De hecho, investigaciones sobre neuromarketing indican que niveles altos de activación emocional aumentan la propensión a la compra impulsiva, incluso en ausencia de una evaluación racional completa (Camerer y Yoon, 2019).

De hecho, contrario a lo esperado, variables clásicas como promociones visibles o la interacción con el personal tuvieron menor peso predictivo. Este resultado contradice parcialmente los supuestos del marketing tradicional (Kotler y Keller, 2016), y puede

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

deberse al fenómeno de saturación publicitaria y al escepticismo creciente de los consumidores (Campbell y Grimm, 2019). Es decir, en un entorno donde el consumidor está expuesto constantemente a estímulos de venta, su sensibilidad a las promociones puede verse diluida (Espitaleta et al., 2022).

Por otro lado, factores como la limpieza y organización del local, que podrían parecer secundarios, adquirieron mayor importancia. Esto concuerda con estudios como los de Spence (2014), que subrayan el valor del ambiente físico como parte integral de la experiencia sensorial de compra.

La regresión logística, modelo clásico en clasificación binaria, superó a random forest en todas las métricas. Esto puede explicarse por la cantidad limitada de datos ($n = 300$) y por el hecho de que los árboles de decisión, al ser más flexibles, tienden a requerir volúmenes mayores para capturar patrones complejos sin sobreajustarse (Hastie et al., 2009).

Pese a esto, la importancia relativa extraída del random forest ofrece una visión más matizada de la contribución de cada variable, revelando el potencial oculto de aquellas que no mostraban correlaciones significativas. Esta complementariedad metodológica apoya lo sugerido por Rokni et al. (2020): la integración de análisis estadístico y modelos de machine learning permite una mejor comprensión de fenómenos multidimensionales como el comportamiento del consumidor.

La principal limitación radica en la subjetividad de los autorreportes emocionales, como señalan Schwarz y Clore (2007), quienes afirman que los estados afectivos son volátiles y sensibles al contexto. Asimismo, el estudio carece de variables conductuales objetivas, como duración de permanencia en tienda, rutas de desplazamiento o gasto final, aspectos que han demostrado ser predictivos en investigaciones previas (Underhill, 1999; Hui et al., 2013).

También se debe señalar que el diseño transversal impide establecer relaciones causales. Si bien los resultados muestran asociaciones y patrones predictivos, no permiten afirmar que una emoción específica cause la decisión de compra.

Los resultados del estudio sugieren que las estrategias de marketing en retail físico deberían focalizarse no solo en promociones, sino también en mejorar el ambiente emocional del punto de venta. Esto incluye factores como la música ambiental, iluminación, limpieza, e interacción humana empática.

Además, las marcas podrían beneficiarse del uso de tecnologías emocionales, tales como sensores de reconocimiento facial o dispositivos de respuesta galvánica, siempre que se resguarden principios éticos y de privacidad (Morozov, 2013). Tales herramientas permitirían capturar datos emocionales más fiables y en tiempo real.

La superioridad de la regresión logística sobre el random forest, a pesar de la sofisticación de este último, podría explicarse por la limitación del conjunto de datos, lo que refuerza la importancia de considerar el tamaño y la calidad muestral al momento de seleccionar modelos predictivos (Hastie et al., 2009). No obstante, la utilidad del random forest radica en revelar la estructura interna y compleja de los datos.

Este estudio pone en evidencia la importancia de enriquecer los métodos de recolección emocional. Si bien el modelo SAM es útil para estandarizar la recolección de datos afectivos, su naturaleza autorreportada limita su precisión. Por ello, se recomienda complementar futuros estudios con técnicas biométricas, como reconocimiento facial o medición de respuestas fisiológicas, que permitan registrar reacciones emocionales en tiempo real (Schwarz y Clore, 2007).

Desde una perspectiva práctica, los hallazgos invitan a reconsiderar las estrategias de marketing en retail físico. Más allá de los incentivos promocionales, se destaca la relevancia

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

de generar ambientes agradables, limpios y emocionalmente estimulantes. Esto se alinea con la propuesta del marketing experiencial y sensorial, que pone énfasis en el diseño del espacio como herramienta de influjo emocional.

Como proyección para futuras investigaciones, se recomienda ampliar la recolección de datos mediante la incorporación de medidas biométricas y observacionales (como reconocimiento facial, respuestas fisiológicas o trazabilidad de movimientos en tienda) que complementen la información autorreportada y reduzcan el sesgo subjetivo. Asimismo, es crucial aumentar el tamaño muestral y diversificar los contextos geográficos y sociodemográficos para mejorar la representatividad y generalización de los hallazgos.

Desde una perspectiva analítica, se sugiere la aplicación de modelos de aprendizaje profundo (deep learning), que permitan captar relaciones no lineales de mayor complejidad entre las variables. Finalmente, se alienta a explorar en profundidad la interacción entre los factores emocionales y los situacionales mediante análisis estadísticos avanzados como la moderación y la mediación, lo cual permitiría entender mejor los mecanismos subyacentes que inciden en la conducta de compra.

LIMITACIONES DEL ESTUDIO

Entre las principales limitaciones del presente estudio se encuentra la naturaleza autorreportada de los estados emocionales, lo que puede introducir sesgos de percepción o deseabilidad social en las respuestas. Aunque se utilizó una escala validada como el modelo SAM, esta herramienta no sustituye métodos biométricos más precisos. Adicionalmente, el diseño transversal de la investigación impide establecer relaciones causales entre las variables analizadas.

Otro aspecto a considerar es el tamaño limitado de la muestra ($n = 300$) y su obtención mediante muestreo por conveniencia, lo cual restringe la generalización de los hallazgos a otras poblaciones o contextos geográficos. Por último, no se incluyeron variables comportamentales objetivas, como tiempo de permanencia, rutas de desplazamiento en tienda o monto gastado, las cuales podrían haber complementado el análisis predictivo.

INVESTIGACIONES FUTURAS

Para avanzar en la comprensión del comportamiento de compra en entornos de retail físico, se sugiere que futuras investigaciones consideren un enfoque mixto que combine instrumentos autorreportados con tecnologías de recolección emocional automatizada, como sensores de reconocimiento facial, pulseras biométricas o cámaras térmicas. Asimismo, resulta pertinente aumentar el tamaño de la muestra y diversificarla en términos demográficos y culturales para obtener resultados más generalizables.

Desde un enfoque metodológico, se recomienda explorar modelos de aprendizaje profundo (deep learning) que puedan capturar interacciones no lineales más complejas entre variables emocionales, contextuales y conductuales. Además, el diseño de estudios longitudinales permitiría observar cambios en la conducta de compra a lo largo del tiempo, así como el impacto de intervenciones sensoriales en tienda. Finalmente, se alienta a profundizar en el análisis ético del uso de datos emocionales en el marketing predictivo, promoviendo prácticas centradas en la privacidad y el consentimiento informado del consumidor.

RECONOCIMIENTOS

Como autores, expresamos nuestro agradecimiento a los participantes que colaboraron voluntariamente en el levantamiento de datos durante sus experiencias de compra en establecimientos de retail físico. De igual manera, se reconoce el apoyo de los diferentes miembros de la comunidad académica de la Universidad Técnica de Machala, así como la

orientación metodológica proporcionada por docentes y asesores de la Facultad de Ciencias Empresariales.

CONTRIBUCIÓN DE COAUTORES

Kleber Francisco Franco Santacruz: fue el responsable de esta investigación. Su trabajo incluyó la conceptualización del estudio, el diseño de la metodología y la ejecución del análisis de datos.

Bill Jonathan Serrano Orellana: actuó como tutor del trabajo de investigación. Su rol fue clave en el asesoramiento metodológico y en la supervisión académica, guiando al autor principal a lo largo de todas las etapas del proyecto.

CONCLUSIONES

Los hallazgos de esta investigación evidencian que la integración de variables emocionales y contextuales en modelos de predicción basados en machine learning aporta un valor añadido significativo al análisis del comportamiento del consumidor en retail físico. A diferencia de los enfoques tradicionales centrados exclusivamente en variables demográficas, este estudio demuestra que el entorno y la afectividad influyen de forma decisiva en la decisión de compra.

El uso de herramientas de aprendizaje automático permitió identificar patrones relevantes entre los estados emocionales, condiciones del ambiente y la probabilidad de realizar una transacción. Esto respalda la viabilidad de construir sistemas predictivos más empáticos y adaptativos, capaces de mejorar la experiencia del consumidor en tiempo real, lo cual representa una ventaja competitiva en el actual panorama del comercio minorista.

Sin embargo, la adopción de estas tecnologías debe estar acompañada de una reflexión ética profunda. La recopilación y el uso de datos emocionales y sensoriales deben garantizar la privacidad, el consentimiento y la transparencia, evitando caer en prácticas invasivas o manipuladoras que atenten contra la autonomía del consumidor.

En conclusión, esta investigación no solo aporta evidencia empírica útil para el desarrollo de soluciones de marketing inteligente, sino que también abre un debate necesario sobre los límites del uso de la inteligencia artificial en contextos comerciales. Futuras líneas de investigación podrían ampliar la muestra, incluir nuevas variables sensoriales o aplicar enfoques experimentales, orientados a diseñar experiencias de compra más personalizadas, responsables y centradas en el ser humano.

REFERENCIAS

- Alves, G., Fonsêca, J., & Maciel, A. (2021). Evaluation of machine learning models for estimating sales in physical retail. En *Anais do IX Symposium on Knowledge Discovery, Mining and Learning (KDMiLe 2021)* (pp. 41–48). Sociedade Brasileira de Computação. <https://doi.org/10.5753/kdmile.2021.17459>
- Burgo Bencomo, O. B., León González, J. L., Cáceres Mesa, M. L., Pérez Maya, C. J., & Espinoza Freire, E. E. (2019). Algunas reflexiones sobre investigación e intervención educativa. *Revista Cubana de Medicina Militar*, 48.
- Camerer, C., & Yoon, C. (2019). Introduction to the Journal of Marketing Research Special Issue on Neuroscience and Marketing. *Journal of Marketing Research*, 52(4), 423-426. <https://doi.org/10.1509/0022-2437-52.4.423> (Original work published 2015)
- Campbell, C., & Grimm, P. E. (2019). The challenges native advertising poses: Exploring potential federal trade commission responses and identifying research needs. *Journal of Public Policy & Marketing*, 38(1), 110-123. <https://doi.org/10.1177/0743915618818576>

- Collins, A., Hamza, O., & Eweje, A. (2022). Revolutionizing edge computing in 5G networks through Kubernetes and DevOps practices. *IRE Journals*, 5(7), 462-463.
- Ćosić, D. (2016). Interdisciplinary description of complex systems. *Scientific Journal*, 14(2), 139-147.
- Csoban-Mirka, E., Esqueda-Henríquez, S., & Ríos, A. (2024). Predicción del comportamiento de compra online: una aplicación del modelo S-O-R. *Retos: Revista de Ciencias de la Administración y Economía*, 14(27), 21-33. <https://doi.org/10.17163/ret.n27.2024.02>
- Dailey, R. (2012). Comportamiento organizacional. *Reino Unido: Escuela de Negocios de Edimburgo Heriot-Watt University*, 50, 37-53.
- Durán, F. J. (2017). Big data aplicado a la mejora de los servicios públicos y protección de datos personales. *Revista de la Escuela Jacobea de Posgrado. edu. mx*, (12), 33-74. https://www.jacobea.edu.mx/revista/numeros/numero12/3.Big_data.Francisco_Duran.pdf
- Espinoza Freire, E. E. (2020). El problema, el objetivo, la hipótesis y las variables de la investigación. *Portal de la Ciencia*, 1(2), 1-71.
- Espinoza Freire, E. E. (2020). El objetivo en la investigación. *Revista Metropolitana de Ciencias Aplicadas*, 3(2), 206-215.
- Espitaleta, J., García, K., & Maza, J. (2022). *Sentiment analysis of reviews to determine the reception of a product using machine learning and data mining techniques / Análisis de sentimientos de reseñas para determinar la acogida de un producto utilizando técnicas de machine learning y data mining*. <http://hdl.handle.net/10584/11237>
- Goleman, D. (2012). Inteligencia emocional. España: Editorial Kairós SA.
- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction* (Vol. 2, pp. 1-758). New York: springer
- Hawkins, D. I., Best, R. J., & Coney, K. A. (2004). *Comportamiento del consumidor: Construyendo estrategias* (9.ª ed.). McGraw-Hill.
- Hui, C., Qi, X., Qianyong, Z., Xiaoli, P., Jundong, Z., & Mantian, M. (2013). Flavonoids, flavonoid subclasses and breast cancer risk: a meta-analysis of epidemiologic studies. *PloS one*, 8(1), e54318. <https://doi.org/10.1371/journal.pone.0054318>
- Hultén, B. (2011). Sensory marketing: the multi-sensory brand-experience concept. *European business review*, 23(3), 256-273.
- International Business Machines. (2023). What is Machine Learning? <https://www.ibm.com/topics/machine-learning>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic markets*, 31(3), 685-695.
- Kotler, P., & Keller, K. L. (2016). A framework for marketing management (6/E). *Baski, Essex: Pearson Education Limited*. https://www.keyano.ca/en/resourcesGeneral/academics/FALL18_MARK4465.pdf
- Ladhari, R., Souiden, N., & Dufour, B. (2017). The role of emotions in utilitarian service settings: The effects of emotional satisfaction on product perception and behavioral intentions. *Journal of Retailing and Consumer Services*, 34, 10-18. <https://doi.org/10.1016/j.jretconser.2016.09.005>

Predicción de compra basada en estados emocionales y factores contextuales en retail físico usando Machine Learning

- Lasso Vivas, V. A. (2024). *Aplicación de la ciencia de datos en la toma de decisiones empresariales en el sector retail* [Proyecto aplicado, Universidad Nacional Abierta y a Distancia – UNAD]. Repositorio Institucional UNAD. <https://repository.unad.edu.co/handle/10596/64309>
- López Mateus, A. (2020). *Alineamiento estratégico de big data en el Instituto Colombiano de Crédito Educativo y Estudios Técnicos en el Exterior Mariano Ospina Pérez - ICETEX* [Tesis de maestría, Universidad Externado de Colombia]. Repositorio Digital Universidad Externado de Colombia. <https://bdigital.uexternado.edu.co/entities/publication/0f513975-e6f5-4dd7-81d4-481109baa827>
- Mannino, A. F. (2021). *La necesidad de la pequeña y mediana empresa de contar con tienda online propia en un ambiente hostil: Análisis de situación en tiempos de pandemia* [Trabajo de investigación de licenciatura, Universidad Nacional de Cuyo]. Biblioteca Digital UNCuyo. https://videlarrivero.bdigital.uncu.edu.ar/objetos_digitales/16830/mannino-fce.pdf
- Morales, D. V., & Pérez, S. G. (2021). *De Silicon Valley a tu negocio: Innovación, data e inteligencia artificial*. ESIC Editorial.
- Morozov, N., & Petrov, Y. (2013). *Dynamics of fracture*. Springer Science & Business Media. 5 jun 2013 - 98 páginas.
- Nguyen, N. T., & Biderman, M. D. (2008). Studying ethical judgments and behavioral intentions using structural equations: Evidence from the multidimensional ethics scale. *Journal of Business Ethics*, 83(4), 627-640.
- Ojika, F. U., Owobu, W. O., Abieba, O. A., Esan, O. J., Ubamadu, B. C., & Daraojimba, A. I. (2022). The impact of machine learning on image processing: A conceptual model for real-time retail data analysis and model optimization. *International Journal of Multidisciplinary Research and Growth Evaluation*, 3(1), 861-875. <https://doi.org/10.54660/IJMRGE.2022.3.1.861-875>
- Ortegón Cortázar, L., & Gómez Rodríguez, A. G. (2016). Gestión del marketing sensorial sobre la experiencia del consumidor. *Revista de Ciencias Sociales*, 22(3), 67-83.
- Peciña, I. S. (2017). *El comercio electrónico: Una guía completa para gestionar la venta online*. ESIC Editorial.
- Puccinelli, N. M., Goodstein, R. C., Grewal, D., Price, R., Raghurir, P., & Stewart, D. (2009). Customer experience management in retailing: understanding the buying process. *Journal of retailing*, 85(1), 15-30. <https://doi.org/10.1016/j.jretai.2008.11.003>
- Rojas Paucar, W. (2024). *Productividad educativa y algoritmos de aprendizaje automático en escuela de ingeniería de sistemas e informática, Universidad Nacional de Moquegua - 2023* [Tesis doctoral, Universidad Nacional de Moquegua]. Repositorio Institucional UNAM. <https://hdl.handle.net/20.500.12990/13407>
- Rokni, M., Ghasemi, V., & Tavakoli, Z. (2020). Immune responses and pathogenesis of SARS-CoV-2 during an outbreak in Iran: Comparison with SARS and MERS. *Reviews in medical virology*, 30(3), e2107. <https://doi.org/10.1002/rmv.2107>
- Russell, J. A. (1980). A circumplex model of affect. *Journal of personality and social psychology*, 39(6), 1161.
- Schwarz, N., & Bless, H. (2007). Mental construal processes: The inclusion/exclusion model. *Assimilation and contrast in social psychology*, 119-141.

https://dornsife.usc.edu/norbert-schwarz/wp-content/uploads/sites/231/2023/11/schwarz___bless_iem_2007_pri.pdf

- Shaytura, S. V., Kozhayev, Y. P., Ordov, K. V., Antonenkova, A. V., & Zhenova, N. A. (2017). Performance evaluation of the electronic commerce systems. *Revista Espacios*, 38(49), 1-10.
- Spence, C. (2022). Experimental atmospherics: a multi-sensory perspective. *Qualitative Market Research: An International Journal*, 25(5), 662-673.
- Spence, P. (2014). Centros y fronteras: el panorama internacional. In *Humanidades Digitales: desafíos, logros y perspectivas de futuro* (pp. 37-61). SIELAE. <https://dialnet.unirioja.es/servlet/articulo?codigo=5181017>
- Tinoco-Egas, R., Juanatey-Boga, Ó., & Martínez-Fernández, V. A. (2019). Generación de emociones en la intención de compra. *Revista de Ciencias Sociales (Ve)*, 25(3), 218-229. <https://www.redalyc.org/articulo.oa?id=28060161018>
- Underhill, D. M., Ozinsky, A., Hajjar, A. M., Stevens, A., Wilson, C. B., Bassetti, M., & Aderem, A. (1999). The Toll-like receptor 2 is recruited to macrophage phagosomes and discriminates between pathogens. *Nature*, 401(6755), 811-815.
- Zaltman, G. (2004). *Cómo piensan los consumidores*. España: Empresa Activa.
- Zhou, D. (2021). Image Recognition of Pledges of Capital Stock in Small-and Medium-Sized Enterprises Based on Partial Differential Equations. *Advances in Mathematical Physics*, 2021(1), 6548344.
- Zunic, E., Korjenic, K., Hodzic, K., & Donko, D. (2020). Application of Facebook's Prophet algorithm for successful sales forecasting based on real-world data [Preprint]. *arXiv*. <https://arxiv.org/abs/2005.07575>