

Plataforma web para la evaluación objetiva de la calidad sensorial del chocolate con machine learning

Web system for the objective evaluation of the sensory quality of chocolate using machine learning

Wladimir A. Carlosviza Amanqui ^A y Fred Torres Cruz ^B

Resumen— Este estudio presenta el diseño, implementación y validación de una plataforma web desarrollada en Python para la evaluación objetiva de la calidad sensorial del chocolate mediante técnicas avanzadas de aprendizaje automático. La evaluación sensorial en la industria chocolatera enfrenta una limitación crítica debido a la subjetividad inherente en las percepciones de consumidores y expertos. Con el fin de superar esta problemática, el sistema propuesto integra datos estructurados sobre ingredientes, origen geográfico y descriptores sensoriales, complementados con valoraciones emitidas por consumidores y catadores expertos. Se entrenó y validó un modelo predictivo basado en el algoritmo XGBoost, alcanzando un error cuadrático medio (RMSE) de 0.3867, superando en precisión a otros modelos de regresión evaluados. La plataforma permite a los usuarios ingresar perfiles de nuevos chocolates, obtener predicciones automáticas de calidad, contribuir con evaluaciones y acceder a análisis detallados. El conjunto de datos empleado comprende más de 1,700 muestras de chocolate evaluadas por expertos de la industria en múltiples regiones de origen. El código fuente y los datos están disponibles públicamente en: <https://bit.ly/4ci1P4Y>

Palabras clave: Calidad Sensorial, Chocolate, Evaluación Objetiva y Machine Learning

Abstract— This study introduces the design, implementation, and validation of a web-based platform, developed in Python, for the objective assessment of chocolate's sensory quality utilizing state-of-the-art machine learning techniques. The intrinsic subjectivity in sensory evaluation—arising from heterogeneous consumer and expert perceptions—poses a significant challenge to the chocolate industry. Addressing this limitation, the proposed system integrates structured data on ingredients, geographic origin, and sensory descriptors, augmented with evaluative scores from both consumers and connoisseurs. A predictive model based on the XGBoost algorithm was trained and rigorously validated, achieving a root mean square error (RMSE) of 0.3867, outperforming alternative regression approaches in predictive accuracy. The platform enables users to input new chocolate profiles, receive automated quality predictions, contribute evaluations, and access in-depth analytical insights. The dataset comprises over 1,700 chocolate samples rated by industry experts across diverse origins. The full source code and dataset are openly available at: <https://bit.ly/4ci1P4Y>

Keywords: Sensory Quality, Chocolate, Objective Evaluation and Machine Learning

1 INTRODUCCIÓN

La industria del chocolate ha experimentado un crecimiento significativo en las últimas décadas [1], la producción bruta mundial de cacao para la temporada 2023/24 será de aproximadamente 4,332 millones de toneladas [2]. Se realizaron estudios en Corea del Sur durante el año 2023, se utilizaron muestras de chocolates comerciales disponibles en el país para evaluar la homogeneidad en la percepción

sensorial de los consumidores [3]. El análisis sensorial tradicional, si bien es crucial para identificar atributos de sabor y calidad, a menudo se ve afectado por la variabilidad humana [4]. Este artículo presenta una plataforma web innovadora que aplica técnicas avanzadas de machine learning para predecir y calificar la calidad sensorial de diversas barras de chocolate de manera objetiva y sistemática [5]. La plataforma integra datos detallados sobre ingredientes, orígenes y características sensoriales de los chocolates, complementados con calificaciones de expertos y consumidores [6]. Esta



Revista de Investigación en Ciencia y Tecnología
ISSN: 2810-8124 (en línea) / ISSN: 2706-543x
Universidad Nacional Micaela Bastidas de Apurímac – Perú

Vol. 7 Núm. 1 (2025) - Publicado: 04/04/25 - [Indexaciones](#)
Número: doi.org/10.57166/riqchary/v7.n1.2025
Páginas: 29-34 | Recibido 01/01/2025; Aceptado 01/02/2025

doi.org/10.57166/riqchary.v6.n1.2025.132

Autores:

A. **ORCID iD** <https://orcid.org/0009-0000-9089-034X>
Wladimir A. Carlosviza Amanqui
Facultad de Ingeniería Estadística e Informática
Universidad Nacional del Altiplano de Puno – UNAP
wcarlosviza@est.unap.edu.pe

B. **ORCID iD** <https://orcid.org/0000-0003-0834-6834>
Fred Torres-Cruz
Facultad de Ingeniería Estadística e Informática
Universidad Nacional del Altiplano de Puno – UNAP
ftorres@unap.edu.pe

combinación permite generar predicciones fiables sobre la calidad del sabor, proporcionando una herramienta valiosa tanto para los fabricantes, que buscan mejorar sus productos, como para los consumidores y entusiastas que desean descubrir los mejores chocolates disponibles [7]. Además de ofrecer predicciones precisas, la plataforma se diferencia por integrar una interfaz de usuario atractiva con funcionalidades comunitarias, permitiendo a los usuarios ingresar información sobre nuevos chocolates, obtener predicciones de calificación y explorar análisis detallados y tendencias en la industria del chocolate [8]. Estas herramientas analíticas avanzadas permiten a los fabricantes comprender mejor los factores que influyen en la calidad de sus productos y tomar decisiones informadas para mejorarlos [9].

En este contexto, se plantea la hipótesis de que la implementación de un sistema basado en machine learning, utilizando el modelo XGBoost, permitirá obtener predicciones más precisas y objetivas sobre la calidad sensorial del chocolate, superando las metodologías tradicionales. El objetivo principal de este proyecto es desarrollar una plataforma web que facilite la evaluación objetiva de la calidad sensorial del chocolate mediante el uso de machine learning, permitiendo así a los usuarios y fabricantes mejorar la comprensión y análisis de los diferentes factores que influyen en la calidad del producto. El proyecto tiene como objetivos específicos identificar y tratar los datos relacionados con las características sensoriales clave que influyen en la calidad del chocolate, diseñar y entrenar un modelo de machine learning que prediga con alta precisión la calidad sensorial del chocolate, y finalmente, validar la precisión y fiabilidad del modelo utilizando métricas cuantitativas como el RMSE.

2 METODOLOGÍA

2.1 Diseño

El diseño del estudio para la plataforma se basa en una investigación cuantitativa que utiliza técnicas de machine learning. Para la evaluación objetiva de la calidad sensorial de las barras de chocolate [10]. Esta investigación corresponde a una investigación aplicada en la cual se evalúa mediante métodos de ingeniería de software la implementación de un nuevo sistema, utilizando un estudio predictivo [11]. La investigación se centra en la creación y validación de un modelo predictivo que integra datos sensoriales y de ingredientes, así como calificaciones de expertos y consumidores [12].

2.2 Población y Muestra

La población de este estudio incluye a fabricantes de chocolate, expertos en cata de chocolate y consumidores de chocolate provenientes de diferentes regiones del mundo, abarcando diversas culturas y preferencias en cuanto a chocolate. Estos participantes calificaron un total de más de 1,700 barras de chocolate de diversas procedencias, incluyendo chocolates de regiones como América del Sur, África y Asia [1]. Dado que el objetivo del análisis es desarrollar un modelo de Machine Learning, se ha optado por utilizar la totalidad del conjunto de datos disponible, sin aplicar técnicas de muestreo, ya que un volumen mayor de datos suele mejorar el rendimiento y la precisión del modelo.

2.3 Técnicas e instrumentos

Para el conjunto de datos se obtuvo de la plataforma Kaggle. El conjunto de datos se titula "Chocolate Bar Ratings". Contiene calificaciones de más de 1,700 barras de chocolate [1].

Con el preprocesamiento se trató previamente el conjunto de datos para manejar valores faltantes y asegurar la calidad. Se utilizó One-Hot Encoding para convertir variables categóricas en formato binario y se aplicaron técnicas de estandarización para mejorar el rendimiento del modelo. La correlación de Pearson se empleó para identificar relaciones lineales entre variables [13]. También utilizamos la división de datos como una medida preventiva contra el sobreajuste. Esto ocurre cuando un modelo de aprendizaje automático se ajusta demasiado bien a los datos de entrenamiento, pero no puede generalizar bien a nuevos datos. Para evitar esto, utilizamos el 80% de los datos para el conjunto de entrenamiento y para el conjunto de datos de prueba, empleamos el paquete `train.test.split` de Python. Usamos el 20% de los datos para probar y validar el modelo propuesto. Esta técnica nos ayuda a reducir el problema del sobreajuste en nuestro modelo.

2.4 Modelo XGBoost Regressor

Se comienza con una predicción inicial, que generalmente es la media de los valores objetivo (y) en el conjunto de entrenamiento [14]

$$\hat{y}_0 = \text{media}(y) \quad (1)$$

El primer árbol predice los residuos (r_1) de las predicciones iniciales y actualiza las predicciones:

$$r_1 = y - \hat{y}_0 \quad (2)$$

$$\hat{y}_1 = \hat{y}_0 + \eta \cdot f_1(x) \quad (3)$$

donde $f_1(x)$ es la predicción del primer árbol.

El segundo árbol se ajusta a los nuevos residuos (r_2) y actualiza las predicciones:

$$r_2 = y - \hat{y}_1 \quad (4)$$

$$\hat{y}_2 = \hat{y}_1 + \eta \cdot f_2(x) \quad (5)$$

La predicción final del modelo se obtiene sumando las predicciones de todos los árboles, ajustadas por la tasa de aprendizaje:

$$\hat{y} = \hat{y}_0 + \eta \cdot f_1(x) + \eta \cdot f_2(x) \quad (6)$$

La ecuación generalizada, para un modelo con M árboles, la predicción final se expresa como:

$$\hat{y} = \hat{y}_0 + \eta \sum_{m=1}^M f_m(x) \quad (7)$$

donde $f_m(x)$ es la predicción del m -ésimo árbol y η es la tasa de aprendizaje.

Cada función $f_m(x)$ representa un árbol de decisión, que se ajusta a los residuos de las predicciones acumuladas de los árboles anteriores. Este proceso permite que el modelo corrija progresivamente los errores y mejore la precisión de las predicciones [15].

2.5 Técnicas de Instrumentos

Para la validez se tomó el error cuadrático medio de la Raíz (RMSE) se empleará para validar la precisión del modelo. Proporciona una medida del error en las mismas unidades que las variables de predicción. Mientras menor sea el RMSE, mejor será la bondad de ajuste o rendimiento del modelo. La confiabilidad del modelo se evaluará mediante las predicciones en diferentes modelos.

2.6 Procedimientos

Se recopiló los datos de la plataforma Kaggle. El conjunto de datos se con el nombre "Chocolate Bar Ratings". Contiene calificaciones de más de 1,700 barras de chocolate [1]. En la tabla 1 se presentan las variables recolectadas que son las siguientes:

TABLA 1
Descripción del conjunto de datos

Variable	Descripción
REF	Valor relacionado con el momento en que se ingresó la reseña en la base de datos.
Company	Referencia al productor que fabrica la barra.
Company Location	País base del fabricante.
Review Date	Año de publicación de la reseña.
Country of Bean	País de origen del grano de cacao.
Origin	
Specific Bean Origin	Región geográfica específica de origen de la barra.
Bar Name	
Cocoa Percent	Porcentaje de cacao (oscuridad) de la barra de chocolate que se está evaluando.
Ingredients	Ingredientes que lleva la barra de chocolate.
Most Memorable Characteristics	Característica más memorable de la que está compuesta la barra.
Rating	Calificación de experto para la barra de chocolate. (variable dependiente)

Nota: Esta Tabla detalla las variables incluidas en un conjunto de datos sobre reseñas de barras de chocolate.

El objetivo de este procedimiento es identificar y realizar un tratamiento adecuado de los datos relacionados con las características sensoriales que influyen en la calidad del chocolate chocolate. Para ello, se analizaron variables clave como la referencia del productor (Company), país de origen del grano de cacao (Country of Bean Origin), porcentaje de cacao (Cocoa Percent), y la calificación de expertos (Rating). Dado que los datos faltantes en la columna de ingredientes representaban menos del 5% del total, se decidió eliminar estas filas para mantener la consistencia del conjunto de datos.

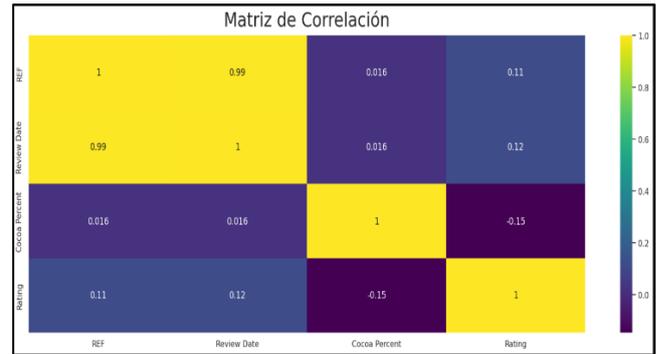


Fig. 1. Matriz de Correlación entre diferentes características del chocolate.

En la Figura 1 se muestra una correlación casi perfecta (0.99) entre REF y la fecha de revisión, indicando una fuerte relación temporal entre ambas variables. Además, hay una correlación positiva moderada (0.15) entre el porcentaje de cacao y la calificación, sugiriendo que, aunque el porcentaje de cacao influye en la calificación, hay otros factores importantes que también la afectan.

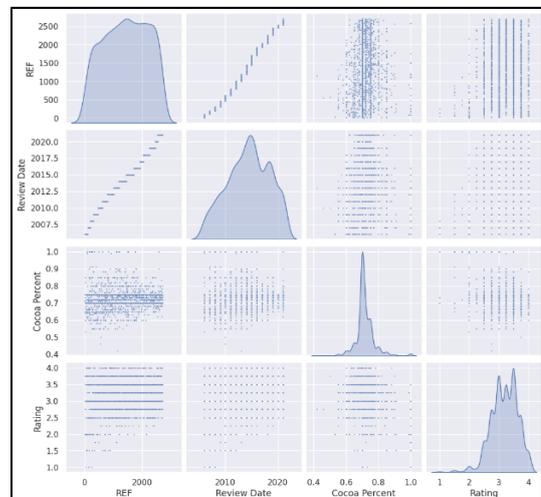


Fig. 2. Matriz de dispersión

En la Figura 2 se observa una relación lineal fuerte entre REF y la fecha de revisión (Review Date). Sin embargo, no se identifica una relación clara entre REF, la fecha de revisión y el porcentaje de cacao (Cocoa Percent). En cuanto a la relación entre REF, la fecha de revisión y la calificación (Rating), se perciben ligeras tendencias positivas. Por último, se observa una leve tendencia negativa entre el porcentaje de cacao y la calificación.

El segundo objetivo de este estudio fue diseñar y entrenar un modelo de machine learning que pueda predecir con alta precisión la calidad sensorial del chocolate. Para lograrlo, se implementó un proceso de preprocesamiento de los datos, que incluyó la transformación de las variables categóricas mediante One-Hot Encoding. Este método se aplicó a las variables "Company", "Company Location", "Country of Bean Origin", "Specific Bean Origin or Bar Name", y "Most Memorable Characteristics", con el fin de convertirlas en un formato

numérico adecuado para el procesamiento por parte del modelo de machine learning. La División de Variables y Conjuntos de Datos: Se identificó la variable Rating como la variable dependiente, y las demás características como variables independientes. Los datos se dividieron en un 80% para el entrenamiento del modelo y un 20% para la prueba y validación, lo que permitió desarrollar un modelo robusto y evitar el sobreajuste.

El tercer objetivo del estudio fue validar la precisión y fiabilidad del modelo de machine learning utilizando métricas cuantitativas como el RMSE. Para el ajuste del modelo se seleccionaron varios modelos de regresión utilizando LazyRegressor, incluyendo AdaBoostRegressor, PassiveAggressiveRegressor, LassoLarsCV, BaggingRegressor, LarsCV, ElasticNetCV, Lars, LinearRegression, TransformedTargetRegressor, HistGradientBoostingRegressor, y XGBRegressor. Estos modelos fueron ajustados para minimizar el RMSE y mejorar la precisión de las predicciones. Se eligió el mejor modelo basado en el menor RMSE, resultando XGBoost como el modelo más preciso y confiable.

3 RESULTADOS

Después de aplicar diversos algoritmos de aprendizaje automático al conjunto de datos, obtuvimos las siguientes precisiones. El modelo de regresión XGBoost es el que ofrece la mayor precisión.

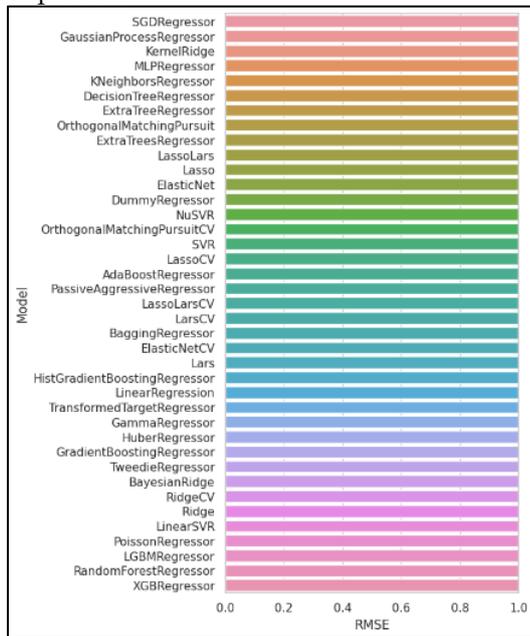


Fig. 3. Evaluación según modelo de regresión

Según la Figura 3 y la tabla 2 se eligió el mejor modelo con LazyRegressor. XGBoost resultó ser el mejor modelo con el menor RMSE. Root Mean Squared Error (XGBoost): 0.3867.

TABLA 2
Comparación de Algoritmos y sus RMSE

Algoritmo	RMSE
AdaBoostRegressor	0.41
PassiveAggressiveRegressor	0.41
LassoLarsCV	0.40
BaggingRegressor	0.40
LarsCV	0.40
ElasticNetCV	0.40
Lars	0.40
LinearRegression	0.40
TransformedTargetRegressor	0.40
HistGradientBoostingRegressor	0.40
XGBRegressor	0.39

Nota: Evaluación Comparativa del Root Mean Square Error (RMSE), o en español, Raíz del Error Cuadrático Medio.

En la tabla 3 se observa las diferentes medidas de rendimiento de XGBRegressor que se comparan con el MAE, MSE, RMSE.

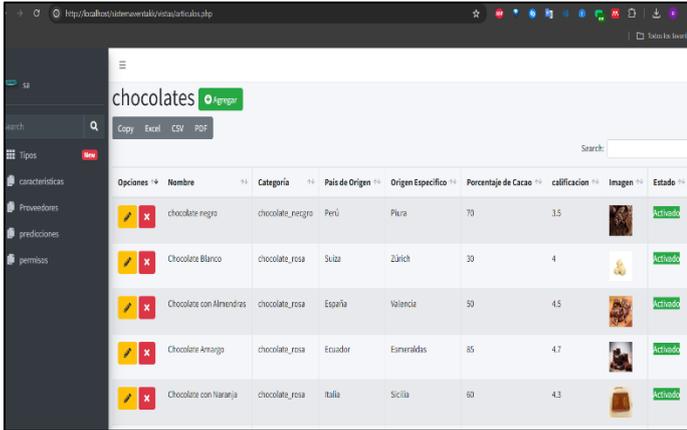
TABLA 3
Resultados del modelo XGBoost Regressor

Métrica	Valor
Mean Absolute Error (XGBoost)	0.3097
Mean Squared Error (XGBoost)	0.1496
Root Mean Squared Error (XGBoost)	0.3867

Nota: Métricas del modelo de regresión basado en árboles de decisión que utiliza técnicas de boosting.

Un MAE de 0.3097 indica que, en promedio, las predicciones del modelo XGBoost están desviadas en 0.3097 unidades de la calidad real del chocolate. Un MAE bajo sugiere que el modelo es bastante preciso en sus predicciones. El MSE de 0.1496 sugiere que el modelo tiene un error cuadrático medio moderado en sus predicciones. Este valor amplifica los errores más grandes, por lo que es útil para identificar grandes desviaciones. RMSE de 0.3867 indica que las predicciones del modelo tienden a desviarse en promedio en 0.3867 unidades de la calidad real del chocolate. Este valor es bastante pequeño lo que indica que el rendimiento es bueno.

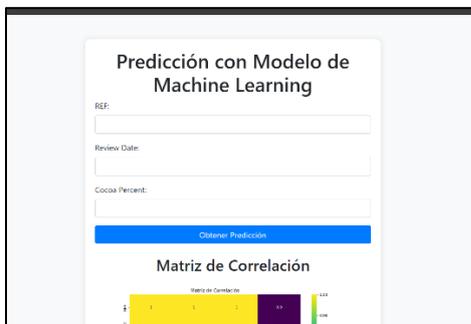
Una de las principales funcionalidades del sistema web es la capacidad de gestionar información detallada sobre diferentes tipos de chocolates. Los usuarios pueden agregar, editar y visualizar información sobre los chocolates, incluyendo su origen, porcentaje de cacao y calificación. La Figura 4 muestra el panel de control de chocolates, donde se puede observar cómo se presenta y organiza esta información.



Opciones	Nombre	Categoría	País de Origen	Origen Específico	Porcentaje de Cacao	calificación	Imagen	Estado
	chocolate negro	chocolate_negro	Perú	Piura	70	3.5		Activado
	Chocolate Blanco	chocolate_resa	Suiza	Zürich	30	4		Activado
	Chocolate con Almonds	chocolate_resa	España	Valencia	50	4.5		Activado
	Chocolate Amargo	chocolate_resa	Ecuador	Esmeraldas	85	4.7		Activado
	Chocolate con Naranja	chocolate_resa	Italia	Sicilia	60	4.3		Activado

Fig. 4. Panel de Control de Chocolates

La plataforma utiliza el modelo de machine learning XGBoost para predecir la calidad sensorial de las barras de chocolate. Los usuarios pueden ingresar datos relevantes en el formulario de predicción, y el sistema genera una predicción basada en estos datos. La Figura 5 muestra la página de predicción, donde se ingresan los datos y se obtiene la predicción.



Predicción con Modelo de Machine Learning

REF:

Review Date:

Cocoa Percent:

Matriz de Correlación

Matriz de Correlación

Fig. 5. Página de Predicción

4 DISCUSIÓN

El modelo XGBoost mostró un excelente desempeño en términos de precisión, con un RMSE de 0.39. Esto indica que el modelo es capaz de predecir con precisión la calidad sensorial de las barras de chocolate. La elección de XGBoost como el mejor modelo fue corroborada por su capacidad para manejar datos con alta dimensionalidad y su eficiencia computacional. En comparación con el estudio de [16], donde se utilizó XGBoost para predecir atributos sensoriales del vino a partir de datos espectrales de uvas, nuestro estudio presenta similitudes en la metodología y resultados, lograron valores de R^2 superiores a 0.7 para varios atributos sensoriales utilizando únicamente datos A-TEEM, lo que destaca la capacidad de XGBoost para manejar datos complejos y multidimensionales de manera efectiva. Mientras que [16], reportaron valores de RMSE inferiores a 1.0 para ciertos atributos sensoriales del vino, nuestro modelo logró un RMSE de 0.39, indicando una alta precisión en la predicción de la calidad sensorial de las barras de chocolate. Además, el uso de técnicas de machine learning en la evaluación sensorial no se limita solo al chocolate. Asimismo, en un estudio [17], donde la

clasificación de cafés especiales utilizando técnicas de machine learning, se lograron tasas de error de clasificación cercanas al 0% al combinar variables sensoriales con datos cuantitativos como la altitud y el método de procesamiento. Este estudio demostró que los modelos de clasificación supervisada pueden distinguir eficazmente entre diversas clases de café, incluso cuando las características sensoriales muestran una alta similitud entre grupos evaluados. La precisión lograda en los estudios anteriores refuerza la eficacia del uso de machine learning en la evaluación sensorial, destacando que modelos como XGBoost pueden identificar sutiles diferencias sensoriales con gran exactitud.

5 CONCLUSIÓN

En este estudio, se abordaron los desafíos asociados a la evaluación sensorial en la industria del chocolate, particularmente la subjetividad y la variabilidad humana, que afectan la precisión y consistencia de las calificaciones de calidad. Con el propósito de superar estas limitaciones, se desarrolló una plataforma web innovadora basada en machine learning para proporcionar una evaluación objetiva y precisa de la calidad sensorial de las barras de chocolate. A continuación, se resumen los logros alcanzados en relación con los objetivos planteados:

En primer lugar, se identificaron y procesaron datos clave relacionados con las características sensoriales del chocolate, como el origen del grano de cacao, el porcentaje de cacao y las calificaciones de expertos. Mediante un preprocesamiento riguroso, que incluyó la eliminación de valores faltantes, One-Hot Encoding y estandarización, se garantizó la calidad y consistencia del conjunto de datos utilizado.

En segundo lugar, se diseñó y entrenó un modelo de machine learning, específicamente el XGBoost Regressor, que demostró ser efectivo para predecir la calidad sensorial del chocolate. Este modelo logró superar la subjetividad de las evaluaciones humanas al generar predicciones basadas en datos cuantitativos, ofreciendo una alternativa estandarizada y reproducible.

En tercer lugar, la fiabilidad del modelo fue validada mediante métricas cuantitativas, destacando un RMSE de 0.3867, lo que refleja un bajo error en las predicciones. Este resultado, superior al de otros modelos de regresión evaluados, confirma la precisión y utilidad de la herramienta desarrollada.

Los hallazgos demuestran que la plataforma resuelve con éxito los problemas de subjetividad y variabilidad en la evaluación sensorial, proporcionando una solución objetiva para la industria del chocolate. Esta tecnología no solo mejora la precisión en la determinación de la calidad del producto, sino que también ofrece a los fabricantes una herramienta valiosa para analizar los factores que influyen en la experiencia sensorial del chocolate.

Las implicaciones de este trabajo son significativas: la plataforma tiene el potencial de optimizar los procesos de control de calidad y producción, permitiendo a los fabricantes ajustar sus productos de manera más informada.

Asimismo, los consumidores podrían beneficiarse de evaluaciones objetivas que respalden sus decisiones de compra. Para futuras investigaciones, se sugiere ampliar el conjunto de datos con más variables sensoriales, explorar otros modelos de machine learning para mejorar la precisión y adaptar esta tecnología a otras áreas de la industria alimentaria donde la evaluación sensorial sea relevante.

En resumen, este estudio cumple con los objetivos establecidos y ofrece una solución innovadora a los desafíos de la evaluación sensorial del chocolate. La plataforma desarrollada representa un avance importante en la aplicación de machine learning para mejorar la calidad de productos alimenticios, abriendo nuevas posibilidades tanto para la industria como para los consumidores.

REFERENCIAS

- [1] R. Tatman, «Kaggle.» [En línea]. Available: <https://www.kaggle.com/datasets/rtatman/chocolate-bar-ratings>. [Último acceso: 2024].
- [2] International Cocoa Organization, «ICCO.» [En línea]. Available: <https://www.icco.org/august-2024-quarterly-bulletin-of-cocoa-statistics/>. [Último acceso: 4 Septiembre 2024].
- [3] J. Lee y J. An, «Consumers' sensory perception homogeneity and liking of chocolate.» *Food Quality and Preference*, vol. 118, p. 105178, 2024. <https://doi.org/10.1016/j.foodqual.2024.105178>
- [4] P. Yolci Omeroglu y T. Ozdal, «Fatty acid composition of sweet bakery goods and chocolate products and evaluation of overall nutritional.» *Journal of Food Composition and Analysis*, vol. 88, p. 103438, 2020. <https://doi.org/10.1016/j.jfca.2020.103438>
- [5] X. Liu, J. Wang, H. Wang, Y. Huang y Z. Ren, «Prediction of prunoidae fruit quality characteristics based on machine learning and spectral characteristic acquisition optimization.» *Food Control*, vol. 165, p. 110627, 2024. <https://doi.org/10.1016/j.foodcont.2024.110627>
- [6] G. Samaras, D. Bikos, P. Cann, M. Masen, Y. Hardalupas, J. Vieira, C. Hartmann y M. Charalambides, «A multiscale finite element analysis model for predicting the effect of micro-aeration on the fragmentation of chocolate during the first bite.» *European Journal of Mechanics - A/Solids*, vol. 104, p. 105221, 2024. <https://doi.org/10.1016/j.euromechsol.2024.105221>
- [7] S. J. Boegman, S. Carodenuto, S. Rebitt, H. Grant y B. Cisneros, «Seeing through transparency in the craft chocolate industry: The what, how, and why of cacao sourcing.» *Journal of Agriculture and Food Research*, vol. 14, p. 100739, 2023. <https://doi.org/10.1016/j.jafr.2023.100739>
- [8] N. Prakansamut, K. Adulpadungsak, S. Sonwai, K. Aryasuk y S. Lilitchan, «Application of functional oil blend-based oleogels as novel structured oil alternatives in chocolate spread.» *LWT*, vol. 203, p. 116322, 2024. <https://doi.org/10.1016/j.lwt.2024.116322>
- [9] C. González, E. V. Acosta, J. C. Mazo Rivas y D. A. Muñoz, «Phenomenological based model for the prediction of the structural changes during chocolate conching process.» *Journal of Food Engineering*, vol. 289, p. 110184, 2021. <https://doi.org/10.1016/j.jfoodeng.2020.110184>
- [10] J. Wagner, J. D. Wilkin, A. Szymkowiak y J. Grigor, «Sensory and affective response to chocolate differing in cocoa content: A TDS and facial electromyography approach.» *Physiology & Behavior*, vol. 270, p. 114308, 2023. <https://doi.org/10.1016/j.physbeh.2023.114308>
- [11] B. Le Révérend, I. Smart, P. Fryer y S. Bakalis, «Modelling the rapid cooling and casting of chocolate to predict phase behaviour.» *Chemical Engineering Science*, vol. 270, pp. 1077-1086, 2019. <https://doi.org/10.1016/j.ces.2010.12.007>
- [12] C. Gallery, S. Bourge y G. Agoda-Tandjawa, «Flow behaviors of multiple molten chocolate matrices: Appropriate curve fitting models and impact of different types of surfactants.» *Journal of Food Engineering*, vol. 363, p. 111780, 2024. <https://doi.org/10.1016/j.jfoodeng.2023.111780>
- [13] S. Kumar y I. Chong, «Correlation analysis to identify the effective data in machine learning: Prediction of depressive disorder and emotion states.» *International Journal of Environmental Research and Public Health*, vol. 15, n° 12, p. 2907, 2020. <https://doi.org/10.3390/ijerph15122907>
- [14] Y. Ren, Z. Lv, Z. Xu, Q. Wang y Z. Wang, «Slurry-ability mathematical modeling of microwave-modified lignite.» *Energy*, vol. 281, p. 128143, 2023. <https://doi.org/10.1016/j.energy.2023.128143>
- [15] T. Chen y C. Guestrin, «XGBoost: A Scalable Tree Boosting System.» *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785-794, 2016. <https://doi.org/10.1145/2939672.2939785>
- [16] C. E.J. Armstrong, J. Niimi, P. K. Boss, V. Pagay y D. W. Jeffery, «Use of Machine Learning with Fused Spectral Data for Prediction of Product Sensory Characteristics: The Case of Grape to Wine.» *Foods*, vol. 12, n° 4, p. 757, 2023. <https://doi.org/10.3390/foods12040757>
- [17] P. C. Ossani, D. F. Rossoni, M. Á. Cirillo y F. M. Borém, «Classification of specialty coffees using machine learning techniques.» *Research, Society and Development*, vol. 10, n° 5, 2021. <https://doi.org/10.33448/rsd-v10i5.14732>