

¿Qué tan bien se puede estimar el agrado por el café negro a partir de respuestas JAR y CATA?

Comparación ampliada de seis modelos predictivos, evaluados por consumidor

RIVERA-VALDEZ Magaly • HERNANDEZ-SALDAÑA Jose Anastasio • RIOS-MERCADO Azucena Yoloxochitl

magaly.riveravldz@uanl.edu.mx • jose.hernandezsal@uanl.edu.mx • azucena.riosmr@uanl.edu.mx

Introducción

¿Cómo leer este póster?

Liking: Calificación global de cuánto agradó el café, en escala de 1 a 9 (Lim, 2011).

JAR: Percepción por debajo, en o por encima del nivel adecuado (Paries et al., 2022).

CATA: Atributos que la persona marca cuando los percibe (Jaeger et al., 2015).

RMSE: Error que penaliza más los desaciertos grandes.

MAE: Diferencia absoluta promedio entre agrado observado y estimado.

Respuestas sensoriales usadas

Familia	Etiquetas
JAR (4)	Temperatura, intensidad de sabor, acidez, sensación en boca
CATA fresco/floral	Té/floral, frutal, cítrico, vegetal verde
CATA tosta-do/dulce	Cereal, nuez, chocolate oscuro, caramelo, tostado, dulce
CATA sabor/sen-sación	Amargo, agrio, astringente, espeso/viscoso
CATA no deseadas	Papel/madera, quemado, hule

Nota: "Acidez" es JAR Acidity; "Agrio" es CATA Sour.

• ATRIBUTOS SENSORIALES •



¿Cuál es el problema?

Un mismo café puede recibir valoraciones distintas porque las personas perciben de manera diferente sabor, acidez, temperatura y sensación en boca. Esta tesina estima qué tan cerca puede predecirse ese agrado a partir de respuestas sensoriales.

Alcance: estimación retrospectiva del agrado en consumidores fuera del entrenamiento, ante las mismas condiciones de café.

¿Qué aporta esta tesina?

Esta tesina complementa el antecedente de predicción con datos sensoriales (Gunning et al., 2026) al comparar seis familias bajo un mismo protocolo.

- Comparar familias bajo condiciones equivalentes.
- Mantener consumidores completos fuera del entrenamiento.
- Seleccionar hiperparámetros dentro de cada entrenamiento.

Metodología

¿Cómo se obtuvieron los datos?

Estudio retrospectivo con **3,186 evaluaciones consumidor-café**, **118 consumidores** y **27 condiciones de café negro**. El agrado se calificó en escala de 1 a 9 y se usaron cuatro respuestas JAR y 17 atributos CATA (Cotter et al., 2021; Ristenpart et al., 2023).


3,186 evaluaciones	118 consumidores
27 condiciones	1–9 escala de agrado

Modelos comparados



Todos recibieron las mismas respuestas sensoriales y las mismas particiones de consumidores.

Validación anidada y ajuste de hiperparámetros



El preprocesamiento se ajustó dentro del pipeline de entrenamiento: imputación, codificación y escalamiento se aprendieron sin usar consumidores de evaluación.

Hiperparámetros evaluados


Familia	Alternativas evaluadas
Ridge, Lasso y Elastic Net	Intensidad y tipo de regularización
Gradient Boosting	Árboles, tasa de aprendizaje y profundidad
KNN	Vecinos, ponderación y distancia
MLP	Arquitectura, regularización y tasa de aprendizaje

Alternativas evaluadas; no son necesariamente los valores seleccionados.

Resultados

Desempeño predictivo

RMSE de cada familia en 3,186 predicciones de consumidores fuera del entrenamiento. Menor es mejor.




Grupo superior: rango de 0.0012 RMSE.

¿Cómo se lee el desempeño?

Para Ridge, el error absoluto promedio fue cercano a un punto de agrado en una escala de 1 a 9. El RMSE puntual fue 1.276; se interpreta junto con la cercanía entre los cuatro modelos superiores (Kuhn & Johnson, 2013). **Comparación prudente:** no establece superioridad estadística fuerte ni un óptimo global.

Contribución predictiva de respuestas

Top 6 para Ridge por importancia de permutación. Δ RMSE indica cuánto aumenta el error al desordenar una respuesta; no implica causalidad.



Conclusiones

Conclusiones

Desempeño práctico. Los líderes estimaron el agrado con un error absoluto promedio cercano a un punto.

Elección prudente. Ridge obtuvo el menor RMSE puntual, pero los cuatro modelos superiores quedaron muy próximos.

Información sensorial útil. Intensidad de sabor y acidez mostraron la mayor contribución predictiva condicional.

Limitaciones de interpretación

- La estimación es retrospectiva, no un pronóstico previo al consumo.
- Los resultados se restringen a consumidores y condiciones comparables a las 27 evaluadas.
- La importancia de variables no expresa causalidad.

Trabajo futuro

- Analizar error por nivel de agrado y por consumidor.
- Diseñar una nueva búsqueda preespecificada para familias con parámetros en borde.
- Evaluar estabilidad de respuestas sensoriales dentro del mismo protocolo.

Referencias

- Cotter, A. R., Batali, M. E., Ristenpart, W. D., & Guinard, J.-X. (2021). Consumer preferences for black coffee are spread over a wide range of brew strengths and extraction yields. *Journal of Food Science*, 86(1), 194–205. <https://doi.org/10.1111/1750-3841.15561>
- Gunning, M., Laforge, M. P. S., Guinard, J.-X., & Tagkopoulos, I. (2026). AI-driven prediction of consumer liking of coffee from sensory data. *npj Science of Food*, 10, 142. <https://doi.org/10.1038/s41538-026-00779-7>
- Jaeger, S. R., et al. (2015). Check-all-that-apply questions for sensory product characterization by consumers. *Food Quality and Preference*, 42, 154–164. <https://doi.org/10.1016/j.foodqual.2015.02.003>
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer. <https://doi.org/10.1007/978-1-4614-6849-3>
- Lim, J. (2011). Hedonic scaling: A review of methods and theory. *Food Quality and Preference*, 22(8), 733–747. <https://doi.org/10.1016/j.foodqual.2011.05.008>
- Paries, M., Bougeard, S., & Vigneau, E. (2022). Multivariate analysis of just-about-right data with optimal scaling approach. *Food Quality and Preference*, 102, 104681. <https://doi.org/10.1016/j.foodqual.2022.104681>
- Ristenpart, W. D., Cotter, A. R., & Guinard, J.-X. (2023). *Consumer preference data for black coffee* [Data set]. Dryad. <https://doi.org/10.25338/B8993H>