

ORIGINAL

Predictive Models of Typographic Preference in Digital Media

Predictivos de Preferencia Tipográfica en Medios Digitales

Ana Lucía Rivera-Abarca¹  , Jazmín Isabel García-Guerra¹  , Héctor Oswaldo Aguilar-Cajas¹  , Heidy Elizabeth Vergara-Zurita¹  , José Israel López-Pumalema²  , Freddy Armijos-Arcos³  

¹Escuela Superior Politécnica de Chimborazo (ESPOCH), Riobamba. Ecuador.

²Universidad Estatal Península de Santa Elena.

³Ingeniería, Diseño y Consultoría (IDYC Cia. Ltda.)

Citar como: Rivera-Abarca AL, García-Guerra JI, Aguilar-Cajas HO, Vergara-Zurita HE, López-Pumalema JI, Armijos-Arcos F. Predictive Models of Typographic Preference in Digital Media. Data and Metadata. 2025; 4:1062. <https://doi.org/10.56294/dm20251062>

Enviado: 04-10-2024

Revisado: 18-02-2025

Aceptado: 09-06-2025

Publicado: 10-06-2025

Editor: Dr. Adrián Alejandro Vitón Castillo 

Autor para la correspondencia: Ana Lucía Rivera-Abarca 

ABSTRACT

Introduction: this article explores how typography influences user experience in digital environments, highlighting its evolution from the 11th century to the Internet era.

Objective: the aim of this research was to examine the psychological impact of fonts, which evoke emotional responses and affect readability, design and user behavior.

Method: predictive models, such as regression, classification and time series, are used to analyze typographic preferences, helping designers to optimize digital interfaces.

Results: the study simulated data from 1 000 participants, considering variables such as age, gender, educational level and context of use, revealing a predominant preference for Sans Serif typefaces (63,3 %), especially in academic reading. The Logistic Regression and SVM models showed a moderate performance (accuracy of 0,627 and 0,634), with better ability to identify preferences for Sans Serif, although with limitations for the minority class (Serif).

Conclusion: it was concluded that psychological, cultural and contextual factors significantly influence preferences, highlighting the need to integrate these variables in future models to improve accuracy and personalization in digital design.

Keywords: Typography; Predictive Modeling; Digital Media; User Preferences; Font Psychology.

RESUMEN

Introducción: este artículo explora cómo la tipografía influye en la experiencia del usuario en entornos digitales, destacando su evolución desde el siglo XI hasta la era de Internet.

Objetivo: el objetivo de la presente investigación fue examina el impacto psicológico de las fuentes, que evocan respuestas emocionales y afectan la legibilidad, el diseño y el comportamiento del usuario.

Método: se emplean modelos predictivos, como regresión, clasificación y series temporales, para analizar preferencias tipográficas, ayudando a diseñadores a optimizar interfaces digitales.

Resultados: el estudio simuló datos de 1 000 participantes, considerando variables como edad, género, nivel educativo y contexto de uso, revelando una preferencia predominante por tipografías Sans Serif (63,3 %), especialmente en lectura académica. Los modelos de Regresión Logística y SVM mostraron un rendimiento moderado (precisión de 0,627 y 0,634), con mejor capacidad para identificar preferencias por Sans Serif, aunque con limitaciones para la clase minoritaria (Serif).

Conclusión: se concluyó que los factores psicológicos, culturales y contextuales influyen significativamente

en las preferencias, subrayando la necesidad de integrar estas variables en futuros modelos para mejorar la precisión y personalización en el diseño digital.

Palabras Claves: Tipografía; Modelos Predictivos; Medios Digitales; Preferencias de Usuario; Psicología de Fuentes.

INTRODUCCIÓN

La tipografía, considerada una forma de arte, tiene una historia fascinante que se remonta hasta el siglo XI, cuando comenzó a utilizarse principalmente en materiales impresos como libros y revistas. Sin embargo, con la llegada de Internet, todo cambió de forma radical. El mundo digital abrió nuevas puertas para la tipografía, llevándola más allá del papel y permitiendo un acceso mucho más amplio a una gran variedad de tipos de letra.^(1,2)

A medida que los medios digitales crecieron, también lo hizo la oferta tipográfica: surgieron fuentes clásicas como Times New Roman, Arial y Helvetica, pero también estilos más recientes y desenfadados como Comic Sans. Esta evolución no solo amplió las opciones disponibles, sino que también impulsó una reflexión constante sobre cómo la tipografía influye en la experiencia del usuario en el entorno digital.^(3,4)

El impacto psicológico de la tipografía juega un papel crucial en cómo los usuarios interactúan con el contenido digital. La psicología de las fuentes revela que diferentes fuentes pueden evocar distintas respuestas emocionales, influyendo en las percepciones, la toma de decisiones y el comportamiento.^(5,6) La selección de tipos de letra, junto con su disposición y tamaño, afecta significativamente la legibilidad y el atractivo estético general de los diseños digitales, por lo que es una consideración crítica en el diseño web.

El modelado predictivo ha surgido como una técnica para analizar las preferencias de los usuarios en tipografía. Este método estadístico aprovecha los datos históricos para pronosticar posibles resultados relacionados con la interacción del usuario con diferentes elementos tipográficos, ayudando a los diseñadores a crear experiencias digitales más eficaces y atractivas.⁽⁷⁾ Al comprender el comportamiento del usuario en relación con las opciones tipográficas, los diseñadores pueden mejorar la coherencia visual y fomentar las conexiones emocionales con su público.⁽⁸⁾ Por lo tanto, la integración de modelos predictivos en tipografía sirve no solo para refinar las opciones estéticas sino también para optimizar la interacción y satisfacción del usuario en los medios digitales.

MÉTODO

Modelos Estadísticos

Modelos predictivos

El modelado predictivo se seleccionó por que juega un papel crucial en la comprensión de las preferencias tipográficas en los medios digitales. Utilizando técnicas estadísticas, los patrones de datos pueden ser analizados para predecir las preferencias y comportamientos del usuario con respecto a la tipografía. Este enfoque permite a los investigadores y diseñadores predecir cómo las diferentes opciones tipográficas podrían influir en el compromiso y la satisfacción del usuario.

Tipos de modelos predictivos

Hay varios tipos de modelos predictivos que se pueden aplicar en el contexto de la tipografía, cada uno con fines únicos, pero se usaron los modelos de regresión, porque pueden predecir resultados continuos, como la calificación general de satisfacción que un usuario podría dar en función de características tipográficas específicas. Al examinar la relación entre las variables independientes (como el tamaño de la fuente, el estilo y el espaciado) y la variable dependiente (satisfacción del usuario), estos modelos pueden revelar qué elementos tipográficos afectan más significativamente a las percepciones del usuario.

Modelos de clasificación

Asimismo, se emplearon los modelos de clasificación categorizan los resultados en grupos distintos. En tipografía, estos modelos se pueden emplear para predecir si un usuario preferirá una fuente sobre otra basándose en sus interacciones y elecciones anteriores. Por ejemplo, al estimar la probabilidad de que un usuario elija una tipografía determinada, los diseñadores pueden adaptar sus ofertas para satisfacer las preferencias del usuario con mayor eficacia.

Modelos de series temporales

También se evaluaron los modelos de series temporales analizan puntos de datos recogidos a lo largo del tiempo, haciéndolos particularmente útiles para observar tendencias en las preferencias tipográficas. Estos modelos pueden ayudar a identificar las variaciones estacionales, tales como los cambios en las preferencias de los usuarios durante determinadas épocas del año, que podrían informar estrategias de diseño durante períodos

pico como vacaciones o eventos

Aplicaciones en medios digitales

La decisión de usar el modelado predictivo en tipografía, fue porque el mismo puede mejorar enormemente la experiencia del usuario al permitir a los diseñadores crear interfaces digitales más personalizadas y atractivas. Al aprovechar los conocimientos obtenidos de estos modelos, las organizaciones pueden tomar decisiones informadas sobre la tipografía que atienden a las preferencias de su público objetivo, aumentando en última instancia el compromiso y la satisfacción del usuario. La integración de modelos predictivos en el entendimiento de las preferencias tipográficas no solo ayuda a crear contenido visualmente atractivo, sino que también se alinea con los aspectos psicológicos del diseño, asegurando que el texto resuene bien con los usuarios. Este enfoque holístico es vital para maximizar la eficacia de los medios digitales en un panorama cada vez más competitivo.

Factores que influyen en la preferencia tipográfica

Se consideraron varios factores clave contribuyen a la preferencia tipográfica entre los usuarios. Impacto psicológico La influencia psicológica de la tipografía es profunda, ya que da forma a la percepción de la marca y la respuesta emocional. La tipografía afecta al tono de la comunicación y a la relevancia contextual, lo que a su vez influye en la forma en que los usuarios interactúan con el contenido, así mismo se consideró el rol que juegan los usuarios a menudo tienen historias personales y antecedentes culturales que moldean sus percepciones de las tipografías, haciendo de la tipografía una experiencia profundamente subjetiva. Esta interacción matizada entre el tipo y la emoción destaca la importancia de considerar factores psicológicos al seleccionar tipografía para medios digitales.

Comportamiento del usuario y toma de decisiones

Dentro del comportamiento del usuario y los procesos de toma de decisiones, se tomaron en cuenta factores como la jerarquía visual y la conexión emocional con el contenido, dado que los sesgos cognitivos y las apelaciones emocionales también juegan un papel en cómo los usuarios responden a diferentes tipos de letra, ya que pueden evocar sentimientos específicos y asociaciones que influyen en el comportamiento del usuario.

Consideraciones de diseño emocional

El concepto de diseño emocional fue evaluado dado que es crucial cuando se evalúan las preferencias tipográficas. Este enfoque hace hincapié en la creación de diseños que susciten sentimientos positivos en los usuarios, aumentando así el compromiso y fomentando un sentido de conexión. El diseño emocional integra elementos como el color, la tipografía y la narrativa para crear interacciones memorables. Ejemplos exitosos, como Airbnb, demuestran cómo las elecciones tipográficas eficaces pueden mejorar los sentimientos de confianza y pertenencia, que son fundamentales en la experiencia del usuario.

Factores culturales y contextuales

Los antecedentes culturales también fueron evaluados, dado que influyen significativamente en la preferencia tipográfica. Los usuarios de diferentes regiones pueden responder de manera diferente a tipos de letra específicos basados en sus historias culturales y las percepciones que la gente tiene sobre la tipografía están influenciadas por sus contextos culturales, lo que sugiere que los diseñadores deben tener en cuenta estas variaciones al hacer elecciones tipográficas.

Datos utilizados

Para este estudio, se desarrolló un modelo de simulación para analizar las preferencias tipográficas en entornos digitales, empleando una muestra simulada de 1,000 participantes. La generación de datos se fundamentó en distribuciones probabilísticas cuidadosamente seleccionadas: una distribución normal ($\mu=35$, $\sigma=12$) para la edad, acotada entre 18 y 70 años; distribuciones categóricas para el género (48 % masculino, 48 % femenino, 4 % otro), nivel educativo (30 % secundaria, 50 % universidad, 20 % postgrado), y contexto de uso (60 % lectura recreativa, 40 % lectura académica). El tiempo de permanencia se modeló mediante una distribución exponencial con media 10, limitada a un máximo de 60 minutos, reflejando patrones realistas de consumo de contenido digital.

La variable dependiente, preferencia tipográfica (Sans-serif vs. Serif), se generó mediante un modelo probabilístico que incorpora múltiples factores de influencia. Este modelo asigna una probabilidad base de 0,5, que se modifica según características específicas del usuario: la edad inferior a 30 años incrementa la probabilidad de preferencia por Sans-serif en 0,1, el uso de dispositivos móviles la aumenta en 0,15, y el contexto académico añade 0,1 adicional.

Conservadoramente, factores como edad superior a 50 años, nivel educativo de postgrado y tiempo de

permanencia extenso (>30 minutos) reducen la probabilidad en 0,1, 0,05 y 0,1 respectivamente, fundamentándose en hallazgos previos de la literatura sobre legibilidad y preferencias tipográficas en medios digitales.

RESULTADOS

El análisis comparativo de los modelos de clasificación revela un rendimiento moderado en la predicción de las preferencias tipográficas de los usuarios. La Regresión Logística y la Máquina de Vectores de Soporte (SVM) exhiben precisiones de validación cruzada ligeramente superiores, con valores de $0,627 \pm 0,052$ y $0,634 \pm 0,063$ respectivamente. Estos resultados sugieren una capacidad predictiva similar entre ambos modelos en términos de exactitud general como se puede observar en la tabla 1.

Tabla 1. Análisis comparativo de los modelos de clasificación.			
Estadístico	Edad	Permanencia	Preferencia Sans_Serif
Muestra	1000	1000	1000
Media	35,08	10,09	0,63
Desviación	11,04	10,11	0,48
Mínimo	18	1	0
25 %	27	2,79	0
50 %	35	6,80	1
75 %	42	14,01	1
Máximo	70	60	1

Al examinar los reportes de clasificación detallados, se observa un patrón consistente en ambos modelos. La clase '1' (presumiblemente la preferencia por la tipografía Sans Serif, dado el resumen estadístico) presenta métricas de precisión, recall y f1-score considerablemente más altas en comparación con la clase '0'. Esto indica que ambos modelos son más efectivos identificando a los usuarios que prefieren las tipografías Sans Serif, aunque con una menor capacidad para identificar correctamente a aquellos que no las prefieren (ver figura 1).




Figura 1. Importancia de variables

Específicamente, la Regresión Logística logra un recall de 0,89 para la clase '1', mientras que el SVM alcanza un valor idéntico. Sin embargo, la precisión para la clase '0' es relativamente baja en ambos casos (Regresión Logística: 0,52, SVM: 0,48), lo que implica una mayor proporción de falsos positivos para esta clase (ver figura 2).

El Random Forest muestra una precisión de validación cruzada similar ($0,631 \pm 0,059$), pero un análisis más detallado revela un rendimiento inferior en las métricas de precisión y recall para ambas clases, resultando en un accuracy general más bajo (0,57). De manera similar, el modelo XGBoost presenta la precisión de validación cruzada más baja ($0,590 \pm 0,043$) y las métricas de clasificación más desfavorables en general como se puede observar en la figura 3.




Figura 2. Importancia de las variables




Figura 3. Importancia de las variables en la predicción de preferencia tipográfica

La evaluación del rendimiento a través de la curva ROC y el cálculo del Área Bajo la Curva (AUC) complementa estos hallazgos. La Regresión Logística obtiene el valor de AUC más alto (0,668), seguido por el SVM (0,608), lo que sugiere una mejor capacidad de discriminación entre las clases en comparación con el Random Forest (0,532) y XGBoost (0,541). Un AUC de 0,5 indicaría una clasificación aleatoria, por lo que los valores obtenidos sugieren una capacidad discriminatoria modesta, siendo la Regresión Logística ligeramente superior en este aspecto (ver figura 4).




Figura 4. Distribución de edad por preferencia tipográfica

El resumen estadístico de las variables ‘Edad’, ‘Tiempo_Permanencia’ y ‘Preferencia_Sans_Serif’ proporciona información descriptiva sobre el conjunto de datos utilizado para entrenar los modelos. La media de ‘Preferencia_Sans_Serif’ de 0,633 indica una prevalencia de usuarios que prefieren este tipo de tipografía en la muestra cómo se indica en la tabla 2.

Tabla 2. Preferencia Sans Serif		
Contexto de Uso	Preferencia Sans Serif = 0	Preferencia Sans Serif = 1
Lectura Académica	108	283
Lectura Recreativa	259	350

Finalmente, la distribución de preferencias por contexto de uso revela una tendencia interesante. En el contexto de 'Lectura Académica', la preferencia por tipografías Sans Serif es notablemente mayor (283) en comparación con las tipografías Serif (108). En contraste, en el contexto de 'Lectura Recreativa', la diferencia es menos pronunciada (Sans Serif: 350, Serif: 259), aunque la preferencia por Sans Serif aún es ligeramente superior. Esta información contextual podría ser crucial para refinar futuros modelos predictivos, posiblemente incorporando interacciones entre las variables demográficas y contextuales.

En conclusión, la Regresión Logística y el SVM demuestran un rendimiento ligeramente superior en la tarea de predicción, aunque con limitaciones en la identificación de usuarios que no prefieren tipografías Sans Serif. La información contextual sobre el uso sugiere que esta variable juega un papel importante en la preferencia tipográfica y podría ser explotada para mejorar la precisión de los modelos en futuras iteraciones.

DISCUSION

Los resultados obtenidos en este estudio revelan un rendimiento moderado de los modelos de clasificación en la predicción de preferencias tipográficas, con la Regresión Logística y SVM mostrando un ligero superioridad en precisión ($0,627 \pm 0,052$ y $0,634 \pm 0,063$, respectivamente). Estos hallazgos coinciden con lo señalado por quienes destacan que modelos lineales como la Regresión Logística suelen ser robustos en tareas de clasificación binaria⁽⁹⁾, especialmente cuando las relaciones entre variables son moderadamente complejas. Sin embargo, el AUC relativamente bajo (0,668 para Regresión Logística) sugiere que la capacidad discriminativa de los modelos es limitada, lo que podría deberse a la naturaleza subjetiva de las preferencias tipográficas, influenciadas por factores psicológicos y contextuales.^(10,11)

Un hallazgo crítico es la disparidad en el rendimiento entre clases: los modelos identifican eficientemente a los usuarios que prefieren tipografías Sans Serif (recall de 0,89), pero fallan en reconocer a quienes no las eligen (precisión $\leq 0,52$). Esto podría relacionarse con el desequilibrio de clases en los datos, donde el 63,3 % de la muestra prefiere Sans Serif, fenómeno documentado en estudios previos sobre sesgos en modelos predictivos.^(12,13)

Además, la baja precisión para la clase minoritaria (Serif) sugiere que los modelos confunden patrones en este grupo, posiblemente por la influencia de variables no consideradas, como el contexto de uso o factores culturales. El análisis contextual reforzó esta hipótesis: en entornos de lectura académica, la preferencia por Sans Serif fue significativamente mayor (283 vs. 108), mientras que en lectura recreativa la diferencia se redujo (350 vs. 259). Esto respalda investigaciones como las de quienes encontraron que el propósito del texto modera las preferencias tipográficas, ya que Sans Serif se asocia con legibilidad en entornos formales [Por otro lado, la menor brecha en contextos recreativos podría deberse a que la tipografía en estos casos se elige por factores emocionales o estéticos].^(14,15)

La inferioridad de Random Forest y XGBoost ($AUC < 0,55$) contradice la noción de que modelos basados en árboles superan automáticamente a los lineales en problemas complejos. Una explicación es que estos algoritmos pueden estar sobreajustando ruido en los datos, especialmente si las variables predictoras (como Edad y Tiempo Permanencia) tienen una relación no lineal débil con la preferencia tipográfica. Esto subraya la importancia de optimizar hiperparámetros y considerar interacciones entre variables, como se sugiere en el modelo de tipografía inteligente.^(16,17)

Los resultados resaltan la necesidad de incorporar variables contextuales y psicológicas en modelos predictivos de tipografía, ya que factores como el estado emocional del usuario o el propósito del texto pueden ser determinantes.^(18,19) Además, técnicas de balanceo de datos o enfoques de ensamble podrían mejorar el rendimiento en la clase minoritaria.⁽²⁰⁾ Finalmente, estudios cualitativos complementarios ayudarían a entender por qué los usuarios asocian ciertas tipografías con contextos específicos, en línea sobre alfabetización visual en medios digitales.⁽²¹⁾

CONCLUSIONES

En conclusión, aunque los modelos lineales mostraron un rendimiento aceptable, su capacidad predictiva está limitada por la complejidad multifactorial de las preferencias tipográficas.

Futuras investigaciones deberían integrar datos psicométricos y diseños experimentales que controlen variables como fatiga visual o carga cognitiva, para avanzar hacia recomendaciones personalizadas más precisas.

REFERENCIAS

1. Bai Y, Huang Z, Gao W, Yang S, Liu J. Intelligent Artistic Typography: A Comprehensive Review of Artistic Text Design and Generation. *APSIPA Trans Signal Inf Process*. 2024;13(1). doi: <http://10.48550/arXiv.2407.14774>.
2. Iluz S, Vinker Y, Hertz A, Berio D, Cohen-Or D, Shamir A. Word-as-image for semantic typography. *ACM Trans Graph*. 2023;42(4):1-11. doi: <http://10.48550/arXiv.2303.01818>.
3. Günay M. The Impact of Typography in Graphic Design. *Int J Eurasia Soc Sci*. 2024;15(57):1446-64. doi: <http://10.35826/ijoes.4519>
4. Tanveer M, Wang Y, Mahdavi-Amiri A, Zhang H. Ds-fusion: Artistic typography via discriminated and stylized diffusion. In: *Proc IEEE/CVF Int Conf Comput Vis*. 2023:374-84. doi: <http://10.48550/arXiv.2303.09604>.
5. Kim S, Jung AR, Kim Y. The effects of typefaces on ad effectiveness considering psychological perception and perceived communicator's power. *J Mark Commun*. 2021;27(7):716-41. doi: <http://10.15444/GMC2018.08.08.05>.
6. Brown NB. The Cognitive Type Project--Mapping Typography to Cognition. *arXiv*. 2024. doi: <http://10.48550/arXiv.2403.04087>.
7. Ezzeldeen O. The Abstract Character of Typography Art. *J Des Sci Appl Arts*. 2024;5(2):40-8. doi: <http://10.21608/jdsaa.2024.229906.1365>.
8. Poon ST. Typography design's new trajectory towards visual literacy for digital mediums. *Stud Media Commun*. 2021;9(1):9. doi: <http://10.11114/smc.v9i1.5071>.
9. Haenschen K, Tamul DJ, Collier JR. Font matters: Understanding typeface selection by political campaigns. *Int J Commun*. 2021;15:21. Available from: <https://ijoc.org/index.php/ijoc/article/view/17615>.
10. Rosidah S, Ivan FX, Murnani S, Nurlatifa H, Nugraha KA, Wibirama S. Impact of Color, Shape, and Typeface on Visual Attention: An Eye Tracking Study on Brand Logo. *ASEAN J Sci Technol Dev*. 2025;42(1):1-17. doi: <http://10.29037/2224-9028.1608>.
11. Rosyid HA, Putra AYH, Akbar MI, Dwiyanto FA. Can Multinomial Logistic Regression Predicts Research Group using Text Input?. *Knowl Eng Data Sci*. 2022;5(2):150-9. doi: <http://10.17977/um018v5i22022p150-159>.
12. Zhang M, Teng L, Xie C, Wang X, Foti L. Serif or sans serif typefaces? The effects of typefaces on consumers' perceptions of activity and potency of brand logos. *Eur J Mark*. 2025;59(4):879-922. doi: <http://10.1108/EJM-06-2023-0497>.
13. Vecino S, Gonzalez-Rodriguez M, Fernandez-Lanvin D, de Andres J. The impact of serif vs sans-serif typefaces on e-commerce websites. *Int J Hum-Comput Interact*. 2025;41(5):3613-24. doi: <http://10.1080/10447318.2024.2338667>.
14. Vecino S, Mehtali J, de Andrés J, Gonzalez-Rodriguez M, Fernandez-Lanvin D. How does serif vs sans serif typeface impact the usability of e-commerce websites?. *PeerJ Comput Sci*. 2022;8:e1139. doi: <http://10.7717/peerj-cs.1139>.
15. Minakata K, Beier S. The dispute about sans serif versus serif fonts: An interaction between the variables of serif and stroke contrast. *Acta Psychol*. 2022;228:103623. doi: <http://10.1016/j.actpsy.2022.103623>.
16. Mushtaq M, Ibrahim A, Adeel M, Murtaza G, Waleed A. Experimental Typography Typeface Design Inspired from Dates Palm Tree Bark Texture. *Eur J Arts Humanit Soc Sci*. 2025;2(1):54-9. doi: [http://10.59324/ejahss.2025.2\(1\).06](http://10.59324/ejahss.2025.2(1).06).
17. Chen W, Yang J, Wang Y. The influence of Chinese typography on information dissemination in graphic design: based on eye-tracking data. *Sci Rep*. 2024;14(1):13947. doi: <http://10.1038/s41598-024-64964-y>.
18. Tatsukawa Y, Shen IC, Qi A, Koyama Y, Igarashi T, Shamir A. FontCLIP: A Semantic Typography Visual-Language Model for Multilingual Font Applications. *Comput Graph Forum*. 2024;43(2):e15043. doi:

<http://10.1111/cgf.15043>.

19. Cheng H, Xiao E, Gu J, Yang L, Duan J, Zhang J, et al. Unveiling typographic deceptions: Insights of the typographic vulnerability in large vision-language models. In: Eur Conf Comput Vis. Cham: Springer; 2024:179-96. doi:10.1007/978-3-031-73202-7_11.

20. Allal Z, Noura HN, Salman O, Chahine K. Leveraging the power of machine learning and data balancing techniques to evaluate stability in smart grids. Eng Appl Artif Intell. 2024;133:108304. doi: <http://10.1016/j.engappai.2024.108304>.

21. Mosleh MA, Gumaeh AH. An Efficient Bidirectional Android Translation Prototype for Yemeni Sign Language Using Fuzzy logic and CNN Transfer Learning Models. IEEE Access. 2024. doi: <http://10.1109/ACCESS.2024.3512455>.

FINANCIACIÓN

Los autores no recibieron financiación para el desarrollo de la presente investigación.

CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

CONTRIBUCIÓN DE AUTORÍA

Conceptualización: Jazmín Isabel García-Guerra.

Curación de datos: Jazmín Isabel García-Guerra.

Análisis formal: Héctor Aguilar-Cajas.

Investigación: Héctor Aguilar-Cajas.

Metodología: Héctor Aguilar-Cajas.

Administración del proyecto: Héctor Aguilar-Cajas.

Recursos: Ana Lucía Rivera-Abarca.

Software: Ana Lucía Rivera-Abarca.

Supervisión: Ana Lucía Rivera-Abarca.

Validación: Jazmín Isabel García-Guerra.

Visualización: Jazmín Isabel García-Guerra.

Redacción - borrador original: Ana Lucía Rivera-Abarca. Jazmín Isabel García-Guerra. Héctor Oswaldo Aguilar-Cajas. Heidy Elizabeth Vergara-Zurita. José Israel López-Pumalema. Freddy Armijos-Arcos.

Redacción - revisión y edición: Ana Lucía Rivera-Abarca. Jazmín Isabel García-Guerra. Héctor Oswaldo Aguilar-Cajas. Heidy Elizabeth Vergara-Zurita. José Israel López-Pumalema. Freddy Armijos-Arcos.