

*Médico investigador. Universidad de Santander, Facultad de Medicina, Bucaramanga, Colombia. <https://orcid.org/0009-0001-5758-5965>

**Médico especialista en medicina interna. Universidad de los Andes, Facultad de Medicina, Mérida, Venezuela. <https://orcid.org/0000-0001-9306-0413>

***Médico especialista en medicina interna. Universidad Autónoma de Bucaramanga, Facultad de Medicina, Colombia. <https://orcid.org/0000-0002-1103-9598>

****Médico especialista en medicina familiar. Universidad de Santander, Facultad de Medicina, Bucaramanga, Colombia. <https://orcid.org/0000-0002-4742-0403>

Personalización de modelos y entrenamiento con tensorflow: desafíos importantes para la medicina actual

Model Personalization and Training with TensorFlow: Important Challenges for Modern Medicine

Personalização e treinamento de modelos com tensorflow: desafios importantes para a medicina moderna

Jorge Andrés Hernández-Navas,* Luis Dulcey- Sarmiento,** Jaime Gómez- Ayala,*** Juan Sebastián Therán-León.****

DOI: 10.62514/amf.v27i3.149

La inteligencia artificial (IA) está transformando la medicina, con avances significativos en diagnóstico, pronóstico y personalización de tratamientos. Entre las herramientas disponibles, *TensorFlow* se ha consolidado como una de las plataformas más poderosas para el desarrollo y entrenamiento de modelos de aprendizaje automático en el ámbito médico. La posibilidad de personalizar modelos en función de datos clínicos específicos ha abierto nuevas oportunidades para la detección temprana de enfermedades, la estratificación de riesgos y la optimización en la toma de decisiones clínicas. No obstante, el entrenamiento de modelos en entornos médicos plantea desafíos significativos, relacionados con la calidad de los datos, la interpretabilidad de los modelos y su integración en la práctica asistencial.¹

El desarrollo de modelos personalizados con *TensorFlow* permite analizar grandes volúmenes de datos provenientes de diversas fuentes, como:

- imágenes médicas
- registros electrónicos de salud
- datos genómicos
- biomarcadores.

La capacidad de entrenar redes neuronales profundas para identificar patrones complejos ha revolucionado múltiples especialidades médicas. Por ejemplo, en radiología, los modelos basados en *redes neuronales convolucionales* (CNN, por sus siglas en inglés) han demostrado una precisión comparable, e incluso superior, a la de radiólogos humanos en la detección de anomalías en mamografías, resonancias magnéticas y tomografías computarizadas. En cardiología, el entrenamiento de modelos con datos provenientes de electrocardiogramas ha permitido la detección precoz de arritmias y otros trastornos cardíacos con alta sensibilidad y especificidad.²

Uno de los aspectos más críticos en la personalización de modelos en medicina es la curación, anonimización y estandarización de los datos clínicos. Los modelos de IA requieren grandes volúmenes de datos

de alta calidad para lograr una adecuada generalización. Sin embargo, la anotación manual de datos clínicos es un proceso costoso y sujeto a variabilidad interobservador, lo cual puede afectar el desempeño del modelo. Además, la privacidad y seguridad de los datos médicos son preocupaciones prioritarias, ya que el uso de información sensible debe cumplir con regulaciones como el reglamento General de Protección de Datos (GDPR) y la Ley de Portabilidad y Responsabilidad del Seguro de Salud (HIPAA), en Estados Unidos y, en el contexto colombiano, la Ley 1581 de 2012 sobre protección de datos personales. Esta última establece disposiciones generales para la protección de datos personales y es supervisada por la Superintendencia de Industria y Comercio (SIC).⁴ Para mitigar estos riesgos, el *aprendizaje federado* ha surgido como una alternativa prometedora, al permitir el entrenamiento de modelos sin necesidad de transferir los datos fuera de las instituciones médicas, preservando así la privacidad del paciente.²⁻⁴

Otro reto importante en la personalización de modelos es la interpretabilidad. A diferencia de los modelos tradicionales basados en regresión o árboles de decisión, muchos algoritmos de aprendizaje profundo son percibidos como “cajas negras”, lo que dificulta la explicación de sus predicciones. En el ámbito clínico, la falta de transparencia en la toma de decisiones puede generar escepticismo entre los profesionales de la salud y dificultar la adopción de estas tecnologías en la práctica cotidiana. Afortunadamente, herramientas como SHAP (*Shapley Additive Explanations*) y LIME (*Local Interpretable Model-Agnostic Explanations*) han mejorado la interpretabilidad de los modelos, proporcionando información detallada sobre cómo los algoritmos ponderan diferentes variables al generar un diagnóstico o una predicción. Esta transparencia es clave para fomentar la confianza en la IA médica y facilitar su implementación clínica.⁵

En términos de implementación, *TensorFlow* ha facilitado el desarrollo de modelos optimizados para *hardware* especializado, como unidades de

procesamiento gráfico (GPU) y unidades de procesamiento tensorial (TPU), lo que ha acelerado notablemente el entrenamiento y la inferencia de modelos en tiempo real. Además, el auge de la computación en la nube ha permitido, a través de herramientas como *TensorFlow Extended* (TFX), integrar flujos complejos de trabajo de IA en los sistemas hospitalarios,

desde la recolección de datos hasta la validación y monitoreo del desempeño de los modelos en entornos clínicos reales. Por lo que sería deseable que en un futuro cercano estos recursos tecnológicos pudieran desarrollarse en unidades de atención primaria. No obstante, esta implementación requiere de una infraestructura tecnológica adecuada y capacitación del personal médico para garantizar su uso responsable y evitar sesgos en la interpretación de resultados.⁶

A pesar de los avances, aún existen desafíos importantes que deben abordarse para maximizar el impacto de *TensorFlow* en la medicina. La validación externa y la replicabilidad de los modelos siguen siendo limitadas, ya que la mayoría de los estudios se basan en datos de poblaciones específicas. La falta de diversidad en los conjuntos de entrenamiento puede afectar la generalización de los modelos y generar sesgos que comprometan su precisión en poblaciones subrepresentadas. Para superar estas limitaciones, es esencial fomentar la colaboración entre instituciones médicas a nivel global, promoviendo la creación de bases de datos multicéntricas y el desarrollo de modelos adaptativos que puedan ajustarse dinámicamente a nuevas cohortes de pacientes.^{6,7}

En conclusión: la personalización de modelos y el entrenamiento con *TensorFlow* en medicina representan un avance sustancial en la precisión diagnóstica, la predicción de riesgos y la toma de decisiones clínicas. Sin embargo, su implementación efectiva depende de la calidad y diversidad de los datos, la interpretabilidad de los modelos y la disponibilidad de infraestructura adecuada. La integración de enfoques como el aprendizaje federado, los modelos explicables y las plataformas optimizadas para el entorno clínico será clave para que la IA médica sea no sólo eficaz y eficiente, sino también ética, confiable y accesible. Para lograrlo, se requiere una colaboración estrecha entre profesionales de la salud, científicos de datos y desarrolladores, asegurando que la IA complementé el juicio clínico y contribuya al mejoramiento de los resultados en salud.

Referencias

1. Akbari A, Martinez J, Jafari R. A Meta-Learning Approach for Fast Personalization of Modality Translation Models in Wearable Physiological Sensing. IEEE J Biomed Health Inform [Internet]. 2022 Apr 1 [cited 2025 Apr 1];26(4):1516–27. Available from: <https://pubmed.ncbi.nlm.nih.gov/34398767/>
2. Zhao Y, Liu Q, Liu P, Liu X, He K. Medical Federated Model With Mixture of Personalized and Shared Components. IEEE Trans Pattern Anal Mach Intell. 2025 Jan;47(1):433-449. doi: 10.1109/TPAMI.2024.3470072. Epub 2024 Dec 4. PMID: 39331555.
3. Raza M. Federated Learning in AI: How It Works, Benefits and Challenges. Splunk. August 28, 2023. Available from: https://www.splunk.com/en_us/blog/learn/federated-ai.html#:~:text=El%20aprendizaje%20federado%20en%2ointeligencia,un%2osistema%20de%20entrenamiento%2ounificado.
4. Ley 1581 de 2012 - Gestor Normativo [Internet]. Gov.co. [citado el 6 de junio de 2025]. Disponible en: <https://www.funcionpublica.gov.co/eva/gestornormativo/norma.php?i=49981>
5. Zeng X, Linwood SL, Liu C. Pretrained transformer framework on pediatric claims data for population specific tasks. Sci Rep [Internet]. 2022 Dec 1 [cited 2025 Apr 1];12(1). Available from: <https://pubmed.ncbi.nlm.nih.gov/35256645/>
6. Ravishankar H, Paluru N, Sudhakar P, Yalavarthy PK. Information Geometric Approaches for Patient-Specific Test-Time Adaptation of Deep Learning Models for Semantic Segmentation. IEEE Trans Med Imaging [Internet]. 2025 [cited 2025 Apr 1];PP. Available from: <https://pubmed.ncbi.nlm.nih.gov/40031589/>
7. Zhang YC, Kagen AC. Machine Learning Interface for Medical Image Analysis. J Digit Imaging [Internet]. 2017 Oct 1 [cited 2025 Apr 1];30(5):615–21. Available from: <https://pubmed.ncbi.nlm.nih.gov/27730415/>