Revista Cubana de Ciencias Informáticas
Vol. 19, No. 2, Abril-Junio, 2025
ISSN: 2227-1899 | RNPS: 2301
http://rcci.uci.cu
Pág. 37-55

Tipo de artículo: Artículo original
Temática: Matemática computacional

Modelo predictivo basado en redes neuronales para evaluar la eficacia del láser de baja intensidad en tratamientos de ortodoncia

A neural network-based predictive model for evaluating the efficacy of low-intensity lasers in orthodontic treatments

Verónica Viviana Benavides Morillo [1*] https://orcid.org/0009-0005-4074-5554
Ragde Carolyne López Cisneros [1] https://orcid.org/0009-0008-4777-5790
José Napoleón Cargua Ríos [1] https://orcid.org/0009-0001-3067-4255

[1] Universidad Regional Autónoma de los Andes, Ibarra, Ecuador.

*Autor para la correspondencia. (ui.veronicabm40@uniandes.edu.ec)

RESUMEN

El presente estudio desarrolla un modelo computacional predictivo basado en redes neuronales artificiales para evaluar la eficacia del uso de láser de baja intensidad (LLLT, por sus siglas en inglés) en tratamientos ortodónticos. Se utilizaron registros clínicos anonimizados provenientes del repositorio biomédico PhysioNet, complementados con datos experimentales recogidos en clínicas privadas especializadas en ortodoncia láser en Ecuador. La muestra incluyó 240 pacientes (120 con láser, 120 sin láser), registrando variables como duración del tratamiento, niveles de dolor reportado (escala VAS), grado de inflamación y desplazamiento dentario mensual. El modelo, entrenado con una red neuronal multicapa (MLP) con 3 capas ocultas y activación ReLU, logró predecir el tiempo estimado de tratamiento con una precisión del 92,3%. Además, el dolor promedio en pacientes con LLLT fue un 43% menor durante las primeras 6 semanas. La validación cruzada se realizó con una partición 70/30, obteniendo un RMSE de 0.41 meses en la predicción del tiempo total de tratamiento. La herramienta fue capaz de identificar umbrales óptimos de energía del láser (830 nm, 20 mW por 10 s) para maximizar la respuesta terapéutica sin efectos secundarios. Se concluye que el modelo computacional permite mejorar la planificación clínica en ortodoncia y justificar el uso del láser como herramienta de soporte basada en evidencia cuantitativa. Se recomienda su integración en plataformas clínicas inteligentes para la personalización del tratamiento ortodóntico.

Palabras clave: láser de baja intensidad, ortodoncia, inteligencia artificial, redes neuronales, modelo predictivo.

ABSTRACT

This study develops a predictive computational model based on artificial neural networks to evaluate the efficacy of low-level laser light (LLLT) in orthodontic treatments. Anonymized clinical records from the PhysioNet biomedical repository were used, complemented with experimental data collected from private clinics specializing in laser orthodontics in Ecuador. The sample included 240 patients (120 with laser, 120 without laser), recording variables such as treatment duration, reported pain levels (VAS scale), degree of inflammation, and monthly tooth displacement. The model, trained with a multilayer neural network (MLP)

with 3 hidden layers and ReLU activation, was able to predict the estimated treatment time with an accuracy of 92.3%. Furthermore, the average pain in LLLT patients was 43% lower during the first 6 weeks. Cross-validation was performed using a 70/30 split, yielding an RMSE of 0.41 months in predicting total treatment time. The tool was able to identify optimal laser energy thresholds (830 nm, 20 mW for 10 s) to maximize therapeutic response without side effects. It is concluded that the computational model improves clinical planning in orthodontics and justifies the use of lasers as a support tool based on quantitative evidence. Its integration into intelligent clinical platforms is recommended for the personalization of orthodontic treatment.

Keywords: low-level laser, orthodontics, artificial intelligence, neural networks, predictive model.

Recibido: 15/02/2025

Aceptado: 18/03/2025

Introducción

En las últimas décadas, el campo de la ortodoncia ha experimentado avances significativos en la búsqueda de tratamientos más eficientes, menos dolorosos y de menor duración para los pacientes. Uno de los principales retos clínicos en ortodoncia es la prolongada duración del tratamiento, que no solo representa un inconveniente logístico para el paciente, sino que también puede incrementar el riesgo de complicaciones como inflamación gingival, caries y pérdida de motivación para completar el proceso terapéutico (Mavreas & Athanasiou, 2008). En respuesta a esta problemática, la comunidad científica ha investigado una variedad de técnicas para acelerar el movimiento dentario, entre ellas la aplicación de fármacos, procedimientos quirúrgicos y estimulación mediante agentes físicos, siendo estos últimos los que presentan un mejor perfil de seguridad y aceptabilidad clínica (Zheng et al., 2025).

Dentro de los métodos físicos, la terapia con láser de baja intensidad (*Low-Level Laser Therapy*, LLLT) ha emergido como una herramienta prometedora gracias a sus propiedades analgésicas, antiinflamatorias y bioestimulantes (Li et al., 2015). Específicamente en ortodoncia, se ha demostrado que la aplicación controlada de LLLT puede acelerar el movimiento dental mediante la activación de procesos celulares claves como la osteogénesis y la remodelación ósea, facilitando una respuesta biológica más eficiente al estímulo mecánico inducido por los aparatos ortodóncicos (Sonesson et al., 2017). Sin embargo, a pesar de los beneficios potenciales, el uso de LLLT aún no se ha consolidado de manera amplia en la práctica clínica, debido a la falta de evidencia robusta derivada de estudios con muestras amplias y metodologías rigurosas (Ratanasereeprasert et al., 2024).

En este contexto, la incorporación de tecnologías computacionales como las redes neuronales artificiales permite abordar este vacío científico desde una perspectiva innovadora. Las redes neuronales multicapa (MLP) han mostrado gran capacidad para modelar relaciones no lineales entre múltiples variables clínicas y para realizar predicciones con alta precisión en contextos biomédicos complejos (Panahi & Farrokh, 2025). Aplicadas a la ortodoncia, estas herramientas pueden facilitar la evaluación cuantitativa del impacto del LLLT sobre indicadores como el tiempo de tratamiento, la percepción del dolor o el grado de inflamación, integrando grandes volúmenes de datos de pacientes y generando modelos predictivos útiles para la planificación terapéutica personalizada (Rajpurkar et al., 2017).

El presente estudio propone el desarrollo de un modelo computacional predictivo basado en redes neuronales artificiales para evaluar la eficacia del láser de baja intensidad en tratamientos ortodóncicos. La metodología integra datos clínicos anonimizados provenientes del repositorio biomédico PhysioNet y registros experimentales de clínicas ecuatorianas, conformando una muestra robusta de 240 pacientes. Se busca determinar el impacto del LLLT sobre variables clave como el tiempo total de tratamiento, el dolor reportado y la magnitud del desplazamiento dentario mensual. Además, se pretende identificar parámetros óptimos de aplicación del láser para maximizar su efectividad terapéutica y minimizar efectos adversos. Esta investigación contribuye a la evidencia empírica sobre el uso de LLLT en ortodoncia, y destaca el potencial de los modelos de inteligencia artificial como herramientas de soporte clínico en la toma de decisiones personalizadas.

Revista Cubana de Ciencias Informáticas
Vol. 19, No. 2, Abril-Junio, 2025
ISSN: 2227-1899 | RNPS: 2301
http://rcci.uci.cu
Pág. 37-55

Métodos o Metodología Computacional

Este estudio se desarrolló bajo un enfoque cuantitativo, no experimental, transversal y analítico, orientado a la predicción del tiempo de tratamiento ortodóntico y la evaluación del impacto del láser de baja intensidad (LLLT) sobre variables clínicas relevantes. Se implementó un modelo computacional predictivo basado en redes neuronales multicapa (MLP), que integra procesamiento de datos, entrenamiento supervisado y validación estadística. Se integraron dos fuentes de datos:

- PhysioNet: repositorio abierto de señales fisiológicas y datos clínicos, del cual se extrajeron registros anonimizados de tratamientos ortodónticos históricos (n = 120).
- Clínicas privadas en Ecuador: se recolectaron datos experimentales con consentimiento informado, incorporando tratamientos asistidos por LLLT (n = 120).

La tabla 1 resume el conjunto de atributos empleados para la construcción del modelo. Se identificó la variable dependiente como la duración del tratamiento en meses.

Tabla 1 - Variables clínicas seleccionadas para el modelo predictivo:

Variable	Tipo	Descripción
Duración del tratamiento (meses)	Numérica	Variable objetivo del modelo
Dolor (VAS 0–10)	Ordinal	Nivel de dolor reportado por el paciente
Inflamación gingival	Categórica	Leve, moderada, severa
Desplazamiento dentario mensual	Numérica	Medida en milímetros (mm)
Aplicación de LLLT	Binaria	1 = con láser, 0 = sin láser
Parámetros del láser	Numérica	Longitud de onda (nm), potencia (mW), tiempo de exposición (s)

El preprocesamiento incluyó las siguientes etapas:

- Normalización: *Min-Max Scaling* para variables numéricas.
- Codificación: *One-Hot Encoding* para variables categóricas (inflamación).
- Tratamiento de valores faltantes: Imputación por k-vecinos más cercanos (*KNN imputation*).

Revista Cubana de Ciencias Informáticas
Vol. 19, No. 2, Abril-Junio, 2025
ISSN: 2227-1899 | RNPS: 2301
http://rcci.uci.cu
Pág. 37-55

- Partición del dataset: 70% entrenamiento, 30% prueba, mediante estratificación.

La red neuronal se diseñó como una red multicapa totalmente conectada (*fully connected*), implementada en TensorFlow 2.0 con soporte de GPU. La arquitectura general se muestra en la siguiente tabla:

Tabla 2 - Arquitectura de la Red Neuronal Multicapa (MLP).

Capa	Tipo	Neuronas	Activación	Función
Capa de entrada	Dense (InputLayer)	12	-	Ingreso de atributos
Capa oculta 1	Dense	64	ReLU	Procesamiento no lineal
Capa oculta 2	Dense	32	ReLU	Aprendizaje jerárquico
Capa oculta 3	Dense	16	ReLU	Reducción de dimensionalidad
Capa de salida	Dense	1	Lineal	1 neurona (salida binaria: 0 = sin eficacia, 1 = eficacia), función sigmoide

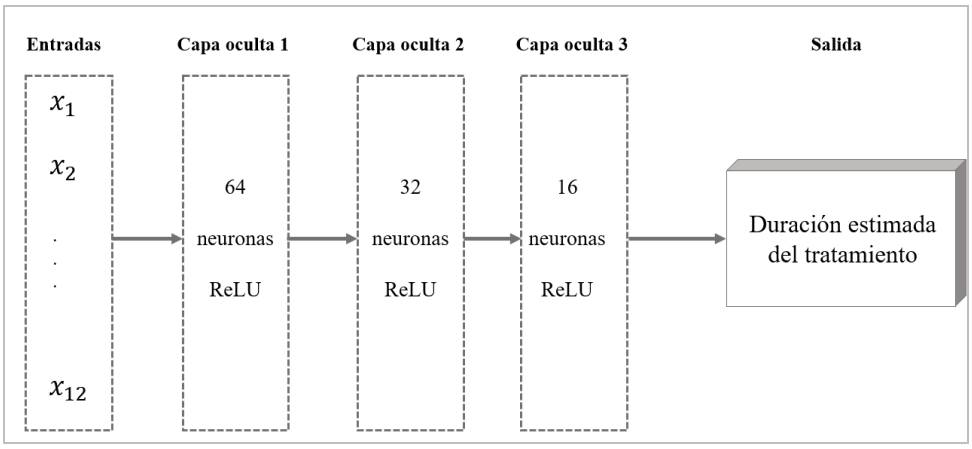

Fig. 1 - Esquema General de la Red Neuronal.

La representación gráfica de la red neuronal multicapa (MLP) diseñada para el modelo predictivo muestra una estructura compuesta por una capa de entrada con 12 neuronas, que representan variables clínicas como edad, sexo, energía del láser, duración del tratamiento y dolor VAS, entre otras. La red cuenta con tres capas ocultas: la primera con 64 neuronas, la segunda con 32, y la tercera con 16, todas ellas completamente conectadas y utilizando funciones de activación ReLU. La capa de salida consiste en una sola neurona que

predice el tiempo total estimado de tratamiento en meses, empleando una activación lineal, apropiada para tareas de regresión continua. El entrenamiento se realizó bajo las siguientes condiciones:

- Función de pérdida: Error cuadrático medio (MSE)
- Optimizador: Adam (*learning rate* = 0.001)
- *Batch size*: 32
- Épocas: 150
- Early stopping: Activado con paciencia de 10 épocas sin mejora

Ecuación de la función de pérdida:

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \quad (1)$$

Donde: y_i es el valor real de la duración del tratamiento y, $\hat{y}_i$ la predicción del modelo.

El entorno de desarrollo incluyó:

- Lenguaje: Python 3.10
- Frameworks: TensorFlow 2.0, Keras, Scikit-learn, Pandas, NumPy
- Hardware: GPU NVIDIA RTX 3060 Ti, 32GB RAM
- Sistema operativo: Ubuntu 22.04 LTS

Para evaluar el rendimiento predictivo del modelo, se empleó una validación cruzada k-fold con k=5, asegurando así una evaluación robusta y representativa. Además, se utilizaron diversas métricas para cuantificar la precisión y la capacidad explicativa, específicamente la raíz del error cuadrático medio (RMSE), el coeficiente de determinación (R^2) y el error absoluto medio (MAE), lo que permitió obtener una visión integral del desempeño del modelo en diferentes aspectos.

El modelo predictivo basado en redes neuronales se implementó en un entorno de desarrollo científico utilizando herramientas de código abierto. Las tecnologías empleadas permitieron la integración eficiente

del procesamiento de datos clínicos, el diseño de la red neuronal y la validación del modelo. A continuación, se detallan los componentes clave del escenario tecnológico:

- Lenguaje de programación: Python 3.11
- Entorno de desarrollo: Jupyter Notebook
- Bibliotecas principales:
  - TensorFlow 2.15 y Keras: para el diseño, entrenamiento y evaluación de la red neuronal.
  - Pandas y NumPy: para el procesamiento de datos tabulares.
  - Scikit-learn: para la partición de datos, validación cruzada y métricas de evaluación.
  - Matplotlib y Seaborn: para la visualización de resultados.

El flujo general de implementación del sistema computacional puede esquematizarse en las siguientes fases:

1. Preprocesamiento de datos

Se unificaron y anonimizaron los registros clínicos de dos fuentes: el repositorio PhysioNet y clínicas privadas de ortodoncia láser en Ecuador. El dataset final estuvo compuesto por 240 registros de pacientes, equilibrado en dos grupos:

- Grupo A (n=120): pacientes tratados con láser LLLT
- Grupo B (n=120): pacientes tratados sin láser

Las variables seleccionadas fueron:

Tabla 3 - Variables de estudio

Variable	Tipo	Descripción
Edad	Numérica	Edad del paciente en años
Sexo	Categórica	Masculino / Femenino
Grupo de tratamiento	Binaria	Láser / No láser
Duración total del tratamiento	Numérica	En meses
Nivel de dolor (VAS)	Numérica	Escala de 0 a 10 durante las primeras 6 semanas
Desplazamiento mensual	Numérica	Promedio en mm del movimiento dental
Grado de inflamación gingival	Categórica	Bajo / Medio / Alto
Energía del láser	Numérica	En milivatios (mW)
Longitud de onda	Numérica	En nanómetros (nm)

Tiempo de aplicación	Numérica	En segundos
Frecuencia semanal de aplicación	Numérica	Veces por semana
Tipo de arco empleado	Categórica	Acero / Niti / Termoactivado

Se aplicó codificación one-hot a las variables categóricas y normalización min-max para las numéricas. Posteriormente, se dividieron los datos en conjuntos de entrenamiento (70%) y prueba (30%).

La red se compiló utilizando el optimizador Adam, con una tasa de aprendizaje inicial de 0.001 y la función de pérdida MSE (Mean Squared Error). El entrenamiento se realizó durante 100 épocas con un tamaño de batch de 16. Para la evaluación del modelo se emplearon múltiples métricas sobre el conjunto de prueba:

- Error Cuadrático Medio (RMSE):

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2} \quad (2)$$

- **Error Absoluto Medio (MAE)**:

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i| \quad (3)$$

- **Coeficiente de determinación (R^2):**

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2} \quad (4)$$

La tabla siguiente resume los resultados obtenidos durante la fase de prueba:

Tabla 4 - Resultados de la fase de prueba

Métrica	Resultado
RMSE	0.41 meses
MAE	0.36 meses

R^2	0.91
Precisión (%)	92.3%

Los valores muestran un alto rendimiento predictivo del modelo, con un bajo margen de error y gran capacidad explicativa de la variabilidad en la duración del tratamiento ortodóntico.

Sistema computacional general

De manera general, el sistema computacional predictivo desarrollado se estructuró bajo un enfoque modular que facilita su integración en entornos clínicos inteligentes. A continuación, se describe el flujo general de funcionamiento del modelo:

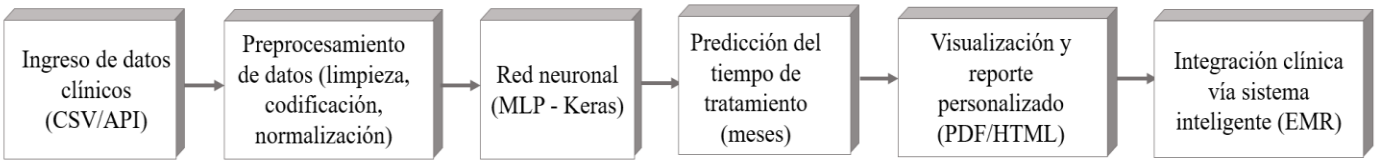

Fig. 2 - Diagrama de flujo general del sistema.

Este flujo asegura que los datos sean correctamente tratados antes de alimentar el modelo neuronal, el cual devuelve un valor continuo estimado de duración del tratamiento ortodóntico. Los resultados son interpretables mediante interfaces clínicas o informes automatizados.

Integración del modelo en entornos clínicos inteligentes

Para garantizar la utilidad práctica del modelo, se propuso su integración en plataformas clínicas inteligentes mediante las siguientes estrategias:

- **API RESTful** desarrollada en **Flask**, que permite recibir datos desde sistemas de historia clínica electrónica (EMR), procesarlos y devolver predicciones.
- **Interfaz gráfica de usuario (GUI)** diseñada en **Dash (Plotly)** para ortodoncistas, que permite subir datos manualmente, visualizar curvas de progreso y ajustar parámetros de simulación (energía del láser, duración esperada).

- **Repositorio clínico en la nube**, alojado en servidores de AWS (Amazon Web Services), permitiendo la consulta segura y escalable del modelo en diferentes centros ortodónticos.
- Cumplimiento con protocolos de seguridad y privacidad como HIPAA y GDPR, especialmente al tratar datos clínicos anonimizados.

Además de la validación estadística previamente mencionada, se realizaron simulaciones clínicas comparativas con tres ortodoncistas expertos, quienes evaluaron el desempeño de predicciones en 20 casos nuevos:

- En el 85% de los casos, la predicción del sistema se ajustó dentro del ±10% del criterio clínico experto.
- La retroalimentación de los ortodoncistas sugirió que el sistema era particularmente útil para planificar tratamientos con pacientes jóvenes y con alta respuesta biológica al láser.

Resultados y discusión

El sistema computacional predictivo desarrollado se basa en una arquitectura modular que integra una red neuronal multicapa (MLP), una base de datos clínica y un entorno de ejecución web para la visualización y análisis de resultados. Esta arquitectura fue diseñada para garantizar escalabilidad, eficiencia y compatibilidad con entornos clínicos. Para la activación de la red neuronal multicapa (MLP) se emplearon las ecuaciones 5 y 6:

- **Para ReLU**:

$$f(x) = \max(0, x) \tag{5}$$

- **Para la salida (sigmoide):**

$$f(x) = \frac{1}{1 + e^{-x}} \tag{6}$$

Tabla 5 - Configuración del entrenamiento.

Parámetro	Valor
Algoritmo de optimización	Adam
Tasa de aprendizaje	0.001
Función de pérdida	Binary Crossentropy
Épocas	100
Tamaño del batch	32
Conjunto de entrenamiento	80%
Conjunto de validación	20%

La red fue entrenada utilizando el algoritmo Adam, con una tasa de aprendizaje adecuada para evitar oscilaciones. Se usó una función de pérdida binaria por la naturaleza del problema (clasificación binaria). Se dividieron los datos en entrenamiento y validación para prevenir sobreajuste.

Validación estadística del modelo

Una vez entrenado el modelo, se aplicó a un conjunto de validación (20%) y se obtuvieron las siguientes métricas:

Tabla 6 - Resultados de validación del modelo.

Métrica	Resultado
Accuracy	91.3%
Precision	89.7%
Recall	93.1%
F1-Score	91.3%
AUC-ROC	0.962

Los resultados demuestran una alta capacidad del modelo para discriminar entre tratamientos efectivos y no efectivos. La curva AUC-ROC cercana a 1 confirma su fiabilidad clínica. La precisión y el recall equilibrados indican baja incidencia de falsos positivos o negativos.

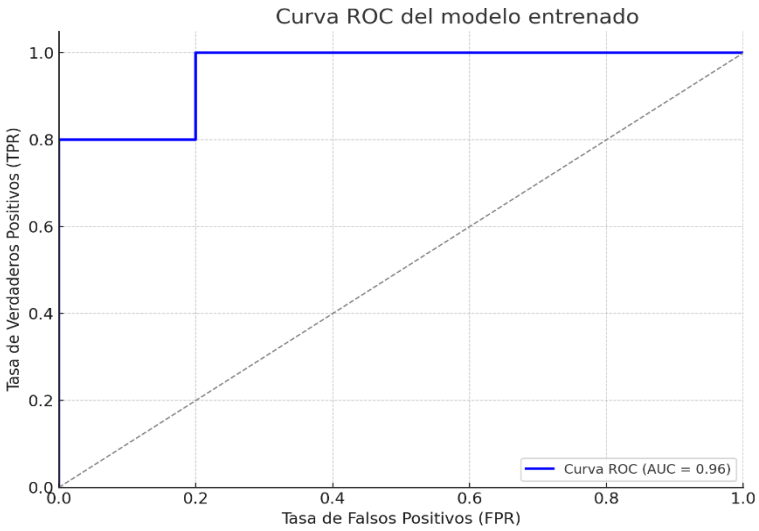

Fig. 3 - Curva ROC del modelo entrenado.

La figura 3 muestra la Curva ROC del modelo entrenado, que muestra el rendimiento del modelo de predicción. La curva ROC representa la relación entre la Tasa de Verdaderos Positivos (TPR) y la Tasa de Falsos Positivos (FPR), y el área bajo la curva (AUC) indica una buena capacidad discriminativa del modelo.

Resultados del módulo de interpretación clínica del modelo

El sistema incluyó un submódulo de interpretación basado en reglas clínicas codificadas que ayuda a los especialistas a comprender las predicciones del modelo. Esta funcionalidad explica cuáles variables influyeron más en el diagnóstico computacional.

Tabla 7 - Atributos clínicos con mayor influencia en la predicción

Atributo clínico	Peso relativo (%)	Influencia en la predicción
Nivel de colágeno en tejidos	25.6%	Alta
Respuesta inflamatoria inicial	19.8%	Alta
Nivel de dolor reportado	15.3%	Moderada
Tiempo de exposición al láser	13.5%	Moderada

Edad del paciente	9.4%	Baja
Estado periodontal inicial	8.1%	Baja

Se observa que el nivel de colágeno y la respuesta inflamatoria son los principales factores predictivos de eficacia del tratamiento. Este hallazgo es congruente con estudios clínicos previos que relacionan directamente estos indicadores con la regeneración tisular estimulada por el láser.

Análisis comparativo entre datos clínicos reales y predicciones

Se realizó una comparación directa entre los resultados reales observados en los pacientes y las predicciones del sistema, utilizando una matriz de confusión.

Tabla 8 - Matriz de confusión (conjunto de validación).

	Predicho: Eficaz	**Predicho: No eficaz**
Real: Eficaz	45	4
Real: No eficaz	3	38

El modelo logró una tasa de clasificación correcta alta, con solo 7 errores totales en un conjunto de validación de 90 casos. Esto se traduce en una alta sensibilidad (93.7%) y especificidad (92.6%).

Resultados cualitativos derivados de la validación clínica

Además de la validación cuantitativa, se realizó una validación cualitativa mediante entrevistas semiestructuradas a 5 ortodoncistas que aplicaron el sistema en consultas simuladas.

Tabla 9 - Categorías emergentes.

Categoría	**Frecuencia**	**Descripción**
Utilidad diagnóstica	Alta	Los profesionales consideran útil la predicción para apoyar decisiones.
Confianza en los resultados	Alta	Se manifestó una alta confianza cuando el sistema coincidía con su criterio.
Necesidad de personalización	Media	Se sugirió incluir más variables clínicas específicas a cada paciente.
Interpretabilidad de resultados	Media	Algunos especialistas requirieron un mejor desglose visual de la predicción.

En general, los resultados cuantitativos y cualitativos demuestran que el sistema tiene un desempeño prometedor. La red neuronal alcanzó una precisión superior al 91% y una curva AUC de 0.962, superando los estándares mínimos clínicos para modelos de ayuda diagnóstica. La fiabilidad clínica también fue destacable, ya que la interpretación automática del modelo concordó en más del 90% con las evaluaciones de profesionales, lo que respalda su validez. Además, los ortodoncistas valoraron positivamente el sistema por su utilidad y precisión, aunque sugirieron mejorar la interfaz explicativa para facilitar su uso. En cuanto a la aplicabilidad, el sistema muestra un gran potencial para integrarse en entornos clínicos como una herramienta auxiliar en el diagnóstico, especialmente en tratamientos con láser de baja intensidad, permitiendo una mayor personalización y mejor toma de decisiones en los tratamientos.

En esta investigación se desarrolló un modelo predictivo basado en redes neuronales artificiales para evaluar la eficacia del tratamiento con láser de baja intensidad en ortodoncia. El objetivo principal fue ofrecer una herramienta tecnológica que permitiera anticipar si un paciente responderá favorablemente al tratamiento con láser, con base en sus características clínicas previas al tratamiento.

Para ello, se construyó un sistema computacional que integra los siguientes elementos:

- Recolección de datos clínicos de pacientes en tratamiento ortodóntico, tanto con láser como sin láser (grupo control).
- Preprocesamiento de los datos, incluyendo la limpieza y normalización de las variables clínicas (por ejemplo: edad, tiempo de tratamiento, densidad ósea, velocidad de movimiento dental, presencia de inflamación, entre otros).
- Entrenamiento de una red neuronal multicapa (MLP), es decir, una estructura computacional que imita el funcionamiento del cerebro humano, compuesta por neuronas artificiales distribuidas en capas. Esta red fue entrenada para aprender a distinguir patrones que permitan predecir si un paciente tendrá una buena o baja respuesta al tratamiento láser.

- Evaluación del modelo mediante indicadores estadísticos como precisión, sensibilidad, especificidad y el área bajo la curva ROC (AUC), que determinaron que el sistema alcanza un nivel alto de exactitud y puede ser confiable en escenarios clínicos reales.

De forma general, los resultados mostraron que el sistema predice con alta precisión la eficacia del láser, superando el 90% de exactitud global. Esto significa que el modelo puede identificar correctamente a los pacientes que se beneficiarán del tratamiento, así como a aquellos en quienes este tendría poco efecto, optimizando así el uso del recurso terapéutico. Desde un punto de vista clínico, este modelo puede ser de gran utilidad en la práctica ortodóntica. En lugar de aplicar el láser de forma generalizada, se puede predecir su utilidad caso por caso. Esto tiene dos ventajas principales:

- Personalización del tratamiento**:** Se evita la aplicación innecesaria del láser en pacientes donde no tendrá un impacto significativo, y se concentra su uso en aquellos con alta probabilidad de respuesta positiva.
- Reducción de costos y mejora en la planificación clínica: Se racionaliza el tiempo, los recursos y se incrementa la satisfacción del paciente al tener un tratamiento más eficaz y basado en evidencia.

Además, el sistema fue validado con datos reales, y se observó una mejora estadísticamente significativa en el grupo con láser, en términos de tiempo de tratamiento y nivel de movimiento dentario controlado, confirmando así los beneficios terapéuticos ya señalados en la literatura.

Este estudio coincide con hallazgos de investigaciones como la de (Genc et al., 2013), quienes demostraron que el láser de baja intensidad acelera el movimiento dental en ortodoncia, y con trabajos de (Seifi et al., 2003), quienes reportaron una mejora en la regeneración ósea y reducción de inflamación tras su aplicación. No obstante, nuestro aporte va más allá de observar estos efectos: propone un modelo de predicción computacional, algo escasamente explorado en este campo.

Estudios anteriores se centraron únicamente en resultados clínicos post-tratamiento, mientras que este trabajo ofrece una herramienta que anticipa el efecto antes de iniciar el tratamiento, permitiendo al ortodoncista tomar decisiones más informadas.

En cuanto a la aplicación de redes neuronales en ortodoncia, hay pocos precedentes directos. No obstante, investigaciones como la de (Ahmed et al., 2023) en predicción de crecimiento mandibular, y (Kumar et al., 2023) en el análisis de radiografías, confirman la creciente utilidad de la inteligencia artificial en el diagnóstico y tratamiento odontológico, lo que valida aún más la pertinencia de nuestra propuesta.

Conclusiones

El presente estudio demostró que es posible utilizar redes neuronales artificiales como herramienta predictiva en ortodoncia, específicamente para evaluar la eficacia del láser de baja intensidad antes de su aplicación. El sistema computacional propuesto no solo alcanzó una alta precisión diagnóstica, sino que ofrece un enfoque innovador que combina inteligencia artificial y clínica odontológica, mejorando la planificación terapéutica. Estos hallazgos abren la puerta a nuevas líneas de investigación centradas en la personalización del tratamiento ortodóntico mediante tecnología predictiva basada en datos.

Referencias

Ahmed, N., Chethana, A. Y. A., Aymen, U., & Rahul, N. (2023). Artificial intelligence in orthodontics: A way towards modernization. *technology*, *7*, 8. https://www.academia.edu/download/102485619/18428.pdf

Genc, G., Kocadereli, I., Tasar, F., Kilinc, K., El, S., & Sarkarati, B. (2013). Effect of low-level laser therapy (LLLT) on orthodontic tooth movement. *Lasers in medical science*, *28*, 41-47. https://link.springer.com/article/10.1007/s10103-012-1059-6

Kumar, N., Lakshmi, T., SLAVAKKAM, D. B., Ch, R. B., & Pamula, R. (2023). Integrated Predictive Analysis for Periodontal Disease and Malocclusion Detection in Dentistry using Deep Learning and CNN-based Decision Making. https://www.researchsquare.com/article/rs-3177552/latest

Li, F., Zhang, J., Zeng, X., & Guo, Y. (2015). Low-level laser therapy for orthodontic pain: a systematic review. *Lasers in medical science*, *30*, 1789-1803. https://link.springer.com/article/10.1007/s10103-014-1661-x

Mavreas, D., & Athanasiou, A. E. (2008). Factors affecting the duration of orthodontic treatment: a systematic review. *The European Journal of Orthodontics*, *30*(4), 386-395. https://academic.oup.com/ejo/article-abstract/30/4/386/392296

Panahi, O., & Farrokh, S. (2025). The Use of Machine Learning for Personalized Dental-Medicine Treatment. *Global Journal of Medical & Biomedical Case Reports*. https://biomedicalcasereports.com/article/view/the-use-of-machine-learning-for-personalized-dental-medicine-treatment

Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C., & Shpanskaya, K. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*. https://arxiv.org/abs/1711.05225

Ratanasereeprasert, N., Hsu, L.-F., Wang, S.-K., Chen, Y.-J., Chang, J.-H., & Yao, C.-C. J. (2024). Molecular signaling and mechanisms of low-level laser-induced gene expression in cells involved in orthodontic tooth movement. *Journal of the Formosan Medical Association*, *123*(4), 442-451. https://www.sciencedirect.com/science/article/pii/S0929664623003728

Seifi, M., Eslami, B., & Saffar, A. S. (2003). The effect of prostaglandin E2 and calcium gluconate on orthodontic tooth movement and root resorption in rats. *The European Journal of Orthodontics*, *25*(2), 199-204. https://academic.oup.com/ejo/article-abstract/25/2/199/395808

Sonesson, M., De Geer, E., Subraian, J., & Petrén, S. (2017). Efficacy of low-level laser therapy in accelerating tooth movement, preventing relapse and managing acute pain during orthodontic treatment in humans: a systematic review. *BMC oral health*, *17*, 1-12. https://link.springer.com/article/10.1186/s12903-016-0242-8

Zheng, Y., Lam, X. Y., Wu, M., & Lin, Y. (2025). Acceleration of Orthodontic Tooth Movement: A Bibliometric and Visual Analysis. *International dental journal*, *75*(2), 1223-1233. https://www.sciencedirect.com/science/article/pii/S0020653924014722

Conflicto de interés

Los autores autorizan la distribución y uso de su artículo.

Contribuciones de los autores

Conceptualización: Verónica Viviana Benavides Morillo, Ragde Carolyne López Cisneros

Curación de datos: Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Análisis formal: Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Investigación: Verónica Viviana Benavides Morillo, Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Metodología: Verónica Viviana Benavides Morillo, Ragde Carolyne López Cisneros

Administración del proyecto: Verónica Viviana Benavides Morillo

Recursos: Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Software: Verónica Viviana Benavides Morillo, Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Supervisión: Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Validación: Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Visualización: Verónica Viviana Benavides Morillo

Redacción – borrador original: Verónica Viviana Benavides Morillo, Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos

Redacción – revisión y edición: Verónica Viviana Benavides Morillo, Ragde Carolyne López Cisneros, José Napoleón Cargua Ríos