

Tipo de artículo: Artículos de revisión

Temática: Ingeniería de software

Recibido: 13/07/2025 | Aceptado: 30/08/2025 | Publicado: 30/09/2025

Identificadores persistentes:

DOI: [10.48168/innosoft.s24.a309](https://doi.org/10.48168/innosoft.s24.a309)

ARK: [ark:/42411/s24.a309](https://nbn-resolving.org/ark:/42411/s24.a309)

PURL: [42411/s24/a309](https://purl.org/42411/s24/a309)

Algoritmos de machine learning para la predicción de la demencia: Revisión sistemática

Machine learning algorithms for dementia prediction: A systematic review

Ricardo Dario Mendoza Rivera¹[\[0000-0001-8744-4736\]](mailto:rmendoza@unitru.edu.pe), Lecca Rengifo Maria Alexandra²[\[0009-0001-0898-1224\]](mailto:t1033300321@unitru.edu.pe), Guido Haro Marco Lucas³[\[0000-0003-1490-5479\]](mailto:mguido@unitru.edu.pe)*, Cruz Ulloa Leydi Marisol⁴[\[0009-0001-7924-1549\]](mailto:T1023300521@unitru.edu.pe), Huamanchumo Gordillo Alexander Saul⁵[\[0009-0008-7571-6245\]](mailto:t1033300121@unitru.edu.pe), Quispe Sanchez Edward Steven⁶[\[0009-0005-0770-2288\]](mailto:esquispes@unitru.edu.pe)

¹Universidad Nacional de Trujillo. Trujillo, Perú. rmendoza@unitru.edu.pe

²Universidad Nacional de Trujillo. Trujillo, Perú. t1033300321@unitru.edu.pe

³Universidad Nacional de Trujillo. Trujillo, Perú. mguido@unitru.edu.pe

⁴Universidad Nacional de Trujillo. Trujillo, Perú. T1023300521@unitru.edu.pe

⁵Universidad Nacional de Trujillo. Trujillo, Perú. t1033300121@unitru.edu.pe

⁶Universidad Nacional de Trujillo. Trujillo, Perú. esquispes@unitru.edu.pe

*Autor para correspondencia: mguido@unitru.edu.pe

Resumen

El trabajo a continuación aborda la identificación de los algoritmos usados en machine learning para la detección temprana de demencia o daño cognitivo degenerativo, en la actualidad uno de los principales desafíos clínicos y socioeconómicos de este siglo. Indica los algoritmos más relevantes en machine learning que con su alta confiabilidad y eficacia están ganando terreno en un mundo mucho más tecnológico. La metodología usada corresponde a las normativas de la declaración PRISMA, utilizando repositorios de alta exigencia investigativa como SCOPUS, SCIELO, IEEE XPLORE, SAGE JOURNAL y GOOGLE ACADEMICO encontrando 15 trabajos que cumplan con todos los criterios establecidos. Los resultados de la revisión en estos trabajos encontraron muchas comparaciones por estudio académico, entre los modelos más utilizados destacan Random Forest y SVM, los cuales han mostrado precisiones superiores al 85 % en múltiples estudios. Las conclusiones afirman la relevancia de Machine Learning como herramienta tecnológica en la detección de demencia y sus variedades, indicando oportunidades para investigaciones futuras, particularmente en casos de estudio más específicos donde el uso de la tecnología es indispensable para ayudar al ser humano.

Palabras claves: Algoritmos, Demencia, Detección, Machine Learning.

Abstract

The following work addresses the identification of algorithms used in machine learning for the early detection of dementia or degenerative cognitive impairment, currently one of the main clinical and socioeconomic challenges of this century. It indicates the most relevant machine learning algorithms that, with their high reliability and effectiveness, are gaining ground in a much more technological world. The methodology used corresponds to the PRISMA declaration standards, using highly demanding research repositories such as SCOPUS, SCIELO,

IEEE XPLORE, SAGE JOURNAL, and GOOGLE SCHOLAR, finding 15 works that met all established criteria. The results of the review in these works found many comparisons by academic study. Among the most widely used models are Random Forest and SVM, which have shown accuracies above 85 % in multiple studies. The conclusions affirm the relevance of Machine Learning as a technological tool in the detection of dementia and its varieties, indicating opportunities for future research, particularly in more specific case studies where the use of technology is essential to assist humans.

Keywords: *Algorithms, Dementia, Detection, Machine Learning.*

Introducción

El incremento en la esperanza de vida ha generado un aumento paralelo en la prevalencia de trastornos neurocognitivos, siendo la demencia uno de los principales desafíos clínicos y socioeconómicos de este siglo. Este síndrome de deterioro progresivo compromete funciones cognitivas esenciales como la memoria, el lenguaje y el razonamiento, afectando la autonomía del paciente e interfiriendo en sus actividades cotidianas. La enfermedad de Alzheimer constituye su causa más frecuente, y aunque su incidencia se relaciona con el envejecimiento, no representa una consecuencia inevitable del mismo.

A pesar de décadas de investigación, los mecanismos fisiopatológicos subyacentes aún no se comprenden completamente y no existe, hasta la fecha, un tratamiento capaz de detener o revertir su progresión. Las principales características neuropatológicas incluyen la acumulación de placas de β -amiloide y ovillos neurofibrilares de proteína tau, altamente asociadas al proceso de neurodegeneración [1]. Además del impacto clínico, las personas con demencia presentan un riesgo de mortalidad dos veces mayor en comparación con grupos sin la enfermedad, así como una alta carga de comorbilidades que aceleran el deterioro funcional. Esta condición también repercute intensamente en el bienestar emocional de los cuidadores, quienes suelen experimentar elevados niveles de estrés y síntomas depresivos [2].

El escenario demográfico actual —marcado por un creciente envejecimiento poblacional— anticipa un aumento significativo en la carga económica de los sistemas de salud. Para contextualizar, en 2014 los costos directos atribuibles a la enfermedad de Alzheimer en Estados Unidos alcanzaron los 214 mil millones de dólares [3]. Frente a la falta de tratamientos curativos y al alto impacto social, el estudio del pronóstico de la demencia se vuelve fundamental. Las estimaciones pronósticas no solo permiten identificar patrones de progresión, sino que también apoyan a las instituciones en la planificación de recursos y a los pacientes y sus familias en la comprensión de la enfermedad. Para lograr esto, es esencial contar con datos clínicos fiables provenientes de ensayos clínicos y estudios longitudinales como ADNI, FINGER o SNAC [4].

Por otro lado [5] tenemos la tecnología de Machine Learning que es un área de la inteligencia artificial que

engloba un conjunto de técnicas que hacen posible el aprendizaje automático a través del entrenamiento con grandes volúmenes de datos. Para [6] esta tecnología ofrece un alto potencial y precisión en la predicción de fenómenos de comportamiento no lineal, tales como los trastornos mentales, en este caso la demencia. Según [7] todo este conocimiento es proporcionado gracias a la Ciencia de Datos mediante la técnica del Machine Learning.

En este contexto, el diagnóstico temprano adquiere especial relevancia, particularmente en etapas prodrómicas como el deterioro cognitivo leve, donde la progresión hacia demencia es variable y difícil de anticipar mediante métodos convencionales [8]. Ante este reto, los algoritmos de machine learning han emergido como herramientas prometedoras, capaces de analizar grandes volúmenes de datos multimodales e identificar patrones complejos que serían difíciles de detectar manualmente [1], [2], [8]. Una revisión sistemática reciente evidenció un incremento significativo en los estudios que emplean machine learning para modelar el riesgo de progresión hacia demencia tipo Alzheimer, a partir de datos clínicos estructurados, neuroimágenes, variables demográficas, resultados de laboratorio y notas médicas extraídas de historias clínicas electrónicas [8].

En este trabajo se presenta una revisión sistemática de los avances recientes en el uso de machine learning para la predicción de demencia. Se analizan comparativamente diferentes arquitecturas algorítmicas, combinaciones óptimas de biomarcadores y los principales desafíos para su implementación clínica. El estudio se centra en modelos predictivos validados con datos clínicos o de neuroimagen publicados en la última década. Los hallazgos sugieren que, aunque estas metodologías muestran un alto potencial predictivo, persisten retos importantes en términos de generalización, interpretabilidad e integración en entornos clínicos reales [1], [8]. Esta revisión busca ofrecer perspectivas clave para el desarrollo de herramientas diagnósticas más robustas, tempranas y accesibles en el abordaje de las demencias.

Metodología

Se llevó a cabo una exhaustiva revisión bibliográfica utilizando como guía la metodología PRISMA por sus siglas en inglés (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). De acuerdo con lo estipulado por [9], este enfoque metodológico favorece la replicabilidad y la actualización de las revisiones de material bibliográfico, lo que en consecuencia permite una presentación más clara, precisa de los hallazgos. Para [10] el uso de esta metodología, garantiza la producción de nuevos saberes en el ámbito de la investigación científica. Además, el autor destaca que las revisiones sistemáticas cumplen un rol importante al permitir identificar el estado actual del conocimiento en un área específica. En este sentido, la aplicación de PRISMA nos ayudará a responder la siguiente pregunta de investigación: ¿Cuáles son los algoritmos más usados de machine learning para la predicción de demencia?

Criterios de inclusión, exclusión y calidad

Con el fin de asegurar que la información recopilada para este trabajo fuera confiable y relevante, se definieron criterios específicos para seleccionar los estudios a analizar. Estos criterios, de inclusión, exclusión y calidad, permitieron filtrar las fuentes más precisas y confiables, garantizando la validez y la pertinencia a la hora de analizar. La descripción detallada de dichos criterios se presenta a continuación en la Tabla 1, Tabla 2 y Tabla 3.

Tabla 1. Criterios de Inclusión

	Criterios de Inclusión
CI1	Antigüedad de máximo 5 años
CI2	Trabajos con relación al tópico de la investigación

Nota. CI= Criterio de Inclusión

Tabla 2. Criterios de Exclusión

	Criterios de Exclusión
CE1	Artículos duplicados
CE2	Trabajos de revisión sistemática
CE3	Trabajos sin relación al tópico de la investigación
CE4	Trabajos sin acceso gratuito

Nota. CE= Criterio de Exclusión

Tabla 3. Criterios de Calidad

	Criterios de calidad
CC1	Autoría y credibilidad
CC2	Diversidad de fuentes
CC3	Actualidad de la información

Nota. CC= Criterio de Calidad

Estrategia de búsqueda

Con el objetivo de hallar y recopilar información de carácter relevante sobre el tema de estudio, se aplicaron estrategias de búsquedas específicas que se detallan a continuación. Se utilizaron muchas combinaciones de palabras clave como “Machine Learning”, “Dementia”, “Prediction”, “Cognitive Decline”, “Artificial Intelligence”, palabras en inglés, para encontrar más literatura sobre el tema, lo que ayudó a expandir el espectro de resultados y acceder a fuentes pertinentes. Estas combinaciones se aplicaron en diversos motores de búsqueda

y bases de datos académicas de acceso libre, lo que facilitó la identificación de estudios enfocados con el tema de algoritmos de machine learning para la predicción de demencia.

En la Tabla 4 se presenta un resumen de los trabajos de investigación encontrados, organizados según la base de datos o motor de búsqueda en el que fueron localizados. Por otro lado, en la Figura 1 se ilustra el diagrama de flujo correspondiente a la metodología PRISMA empleada en esta revisión académica.

Tabla 4. Filtración de artículos por criterios

Base de Datos	Artículos en-contrados	Aplicando CE1	Aplicando CE2	Aplicando CE3	Aplicando CE4
Scielo	41	35	20	6	2
Scopus	1351	1120	311	31	5
IEEE	36	18	8	2	2
Sage Journal	12	11	3	1	1
Google Académico	802	601	12	6	5
TOTAL	2242	1785	354	46	15

Ecuaciones de Búsqueda

Para iniciar con la búsqueda de los artículos a analizar, se implementaron conectores booleanos de variables de estudio, teniendo en cuenta las diversas combinaciones posibles para hallar la información pertinente del tema en cuestión. Con la finalidad de mejorar la precisión en este proceso, se elaboró en la Tabla 5 un aglomerado que incluye la combinación de los términos predefinidos junto con los operadores booleanos detallados para cada uno de los motores de búsqueda y base de datos utilizados en este trabajo.

Tabla 5. Ecuación de Búsqueda por conectores

Repositorio	Cadena de búsqueda
Scielo	(Machine Learning and Prediction and Dementia and Cognitive Decline)
Scopus	TITLE-ABS-KEY (Machine Learning AND Prediction AND Dementia AND Cognitive Decline)
IEEE	(.All Metadata": Dementia) AND (.All Metadata": Machine Learning) AND (.All Metadata": Prediction)
Sage Journal	(.All Keywords": Dementia) AND (.All Keywords": Prediction) AND (.All Keywords": Machine Learning) AND (.All Keywords": Cognitive Decline)
Google Académico	(Machine Learning and Dementia and Prediction and Artificial Intelligence)




Figura 1. Diagrama de flujo PRISMA aplicado en el trabajo

Resultados y discusión

Luego de aplicar todos los criterios definidos de inclusión, exclusión y calidad, se identificaron 15 artículos que cumplen con las condiciones propuestas. A continuación la Tabla 6 presenta un resumen detallado de los artículos seleccionados, lo que permite visualizar con claridad los enfoques investigativos adoptados.

Tabla 6. Resultados de los artículos seleccionados

Nro	Autores	País	Resultados	Algoritmo Machine learning utilizado
1	Ganyi feng, et al.	China	El análisis de enriquecimiento funcional reveló que UBE2N está asociado con el ciclo de vesículas sinápticas y las vías de señalización de los receptores de células T/B.	La factorización matricial (MF) en sistemas de recomendación
2	Mónica Richter-Laskowska, et al.	Polonia	Aquí, el algoritmo Random Forest demuestra un rendimiento superior, logrando una precisión del 84 %, un AUC de 0,96 y un MCC de 0,71. Este modelo supera consistentemente a otras técnicas de aprendizaje automático (ML).	Random Forest
3	Bettina Barisch-Fritz, et al.	USA	La muestra del estudio consistió en 319 PcD (IG,norte= 161; CG,norte= 158). La proporción de personas con discapacidad que experimentaron deterioro cognitivo, en los diferentes dominios medidos, osciló entre el 27 % y el 48 % en el GC y entre el 23 % y el 49 % en el GI, sin diferencias estadísticamente significativas ni efectos de tiempo*grupo. Los modelos de aprendizaje automático mostraron una precisión y valores de AUC que oscilaron entre 40,6 y 75,6.	Máquina de vectores de soporte (SVM)
4	Georgina Waldo-Benítez, et al.	México	Se encontró que el algoritmo k-NN es el que obtiene mayor precisión con un $92.13\% \pm 3.48$, seguido por RF con un $92.0\% \pm 1.8$, a pesar de que obtienen valores muy cercanos, RF no clasifica la categoría de convertido	k- Nearest Neighbors (Vecinos más cercanos)

Nro	Autores	País	Resultados	Algoritmo Machine learning utilizado
5	Charlotte James, et al.	USA	En este estudio de pronóstico de datos de 15.307 asistentes a clínicas de memoria sin demencia, los algoritmos de aprendizaje automático fueron superiores en su capacidad para predecir la demencia incidente en 2 años en comparación con 2 modelos predictivos existentes. Los algoritmos de aprendizaje automático requerían solo 6 variables para alcanzar una precisión de al menos el 90 % y tenían un área bajo la curva característica operativa del receptor de 0,89.	Regresión logística (LR)
6	Nibeth Mena Mamani	España	A partir de los datos (exoma) de un individuo se encontraron 27 variantes genéticas asociadas a la enfermedad del Alzheimer. Posteriormente, con ayuda de las herramientas PLINK y PRSice se calculó la puntuación de riesgo poligénico con distintos modelos obtenidos por medio de estudios asociativos previos (GWAS)	Algoritmo KNN o K vecinos
7	Battista, P., et al.	Italia	En un estudio de 1502 pacientes que presentaban deterioro cognitivo leve, el modelo de SVC superó modelos clínicos tradicionales usando 6 variables neuropsicológicas como el MMSE, la memoria episódica y la edad. Alcanzando una precisión del 85 %	SVM (Support Vector Machine)
8	Pellegrini, E., et al.	Reino Unido/ España	En el uso del algoritmo CNN 3D mostraron que la AUC = 0.89 vs AUC = 0.82 en modelos tradicionales. Requirieron solo 4 biomarcadores de MRI para alcanzar una predicción mayor a 90 %.	Random Forest, CNN, SVM

Nro	Autores	País	Resultados	Algoritmo Machine learning utilizado
9	Dyrba, M., et al.	Alemania	El modelo empleado de 3D-CNN + XG-Boost logró una alta precisión de 92 % para predecir que pacientes con deterioro cognitivo leve podrían tener demencia en un plazo de 2 años.	3D-CNN (Redes Neuronales Convolucionales 3D)
10	Janice M. Ranson, et al.	Reino Unido	Se menciona que los métodos de IA en neuroimagen superan a los enfoques tradicionales, como en el caso de la clasificación diagnóstica utilizando el volumen hipocampal, y se citan más de 250 estudios de IA que abordan preguntas clínicas sobre el diagnóstico o pronóstico de la demencia.	Deep learning, modelos de aprendizaje no supervisado
11	Ashir Javeed, et al.	Suecia	Los modelos basados en imágenes mostraron un rendimiento superior, con precisiones que alcanzaron hasta el 99.99 % en la clasificación de demencia utilizando redes neuronales convolucionales (CNN) y SVM. En contraste, los modelos basados en voz obtuvieron precisiones más bajas, alrededor del 63.6 % con CNN. Los algoritmos más utilizados fueron SVM (26 %), Random Forest (16 %) y CNN (14 %).	SVM (Support Vector Machine), Random Forest (RF), Redes Neuronales Convolucionales (CNN), RNN/LSTM.
12	Alexander Merkin, et al.	Nueva Zelanda	Los modelos de Deep Learning pueden alcanzar una precisión superior al 90 % en la detección y predicción de demencia, superando a los métodos tradicionales de Machine Learning.	Deep Learning y Métodos tradicionales

Nro	Autores	País	Resultados	Algoritmo Machine learning utilizado
13	Danielle Newby, et al.	Reino Unido	Los modelos de Machine Learning (ML) pueden mejorar la predicción del riesgo de demencia y optimizar la selección de participantes para ensayos clínicos. Además, se señala que los enfoques de aprendizaje profundo (deep learning) han logrado una precisión superior al 90 % en la clasificación de deterioro cognitivo leve (MCI) y demencia utilizando datos de neuroimagen.	Deep learning
14	Haewon Byeon	Corea del Sur	Los estudios revisados mostraron altas precisiones en la predicción de demencia, como un 99.52 % con J48 (Bansal et al., 2018), 87 % con MLP y SVM (Zhu et al., 2020), y un AUC de 0.869 con Naive Bayes (Jammeh et al., 2018).	Random Forest, SVM, Naive Bayes, MLP, Decision Tree (J48), AdaBoost, LogitBoost, K-means, SMOTE.
15	Donald M. Lyall, et al.	Reino Unido	Los modelos de machine learning superaron los métodos clínicos tradicionales en la predicción de demencia. Un estudio con 32,573 participantes mostró que los Gradient Boosted Trees lograron un 92 % de precisión, superando a modelos como CAIDE (80 %). Otro modelo combinando SVM y k-NN alcanzó un 97.2 % de precisión en identificar riesgo de demencia.	Gradient Boosted Trees, SVM, k-NN, Random Forest, Neural Networks, Multimodal Transformers, Restricted Boltzmann Machines (RBM).

Los resultados de esta revisión sistemática demuestran que los algoritmos de Machine Learning están revolucionando el campo de la predicción de demencia. Entre los modelos más utilizados destacan Random Forest y SVM, los cuales han mostrado precisiones superiores al 85 % en múltiples estudios. Estos algoritmos han demostrado ser especialmente efectivos al analizar datos clínicos y neuroimágenes, lo que sugiere su potencial para integrarse en entornos médicos reales. Sin embargo, se observa que su rendimiento varía significativamente según el tipo y la calidad de los datos utilizados, lo que subraya la importancia de estandarizar los conjuntos

de datos en futuras investigaciones.

Un hallazgo relevante es el sobresaliente desempeño de las redes neuronales convolucionales (CNN), particularmente en el análisis de neuroimágenes, donde alcanzan precisiones cercanas al 99 %. Este resultado resalta el papel crucial de las técnicas de Deep Learning en el procesamiento de datos complejos como resonancias magnéticas o tomografías. No obstante, estos modelos presentan desafíos importantes en cuanto a interpretabilidad, lo que puede limitar su adopción clínica. La caja negra característica de muchas arquitecturas profundas sigue siendo una barrera que debe abordarse para ganar la confianza de los profesionales de la salud.

Desde una perspectiva geográfica, se identifica una marcada disparidad en la distribución de los estudios. La mayoría de las investigaciones provienen de países desarrollados, con escasa representación de poblaciones latinoamericanas o africanas. Esta brecha podría afectar la generalización de los modelos, ya que factores como la diversidad genética y las condiciones socioeconómicas pueden influir en la manifestación de la demencia. Además, se observa que los países con mayores recursos tienden a emplear técnicas más avanzadas como el Deep Learning, mientras que en regiones con menos acceso a tecnología predominan algoritmos clásicos como k-NN o regresión logística.

Entre las limitaciones más significativas se encuentra el uso de conjuntos de datos pequeños o poco diversos en muchos estudios. Esta restricción afecta directamente la capacidad de los modelos para generalizar sus predicciones a poblaciones más amplias. Asimismo, la falta de estandarización en las métricas de evaluación dificulta la comparación directa entre diferentes algoritmos. Estos aspectos técnicos deben considerarse cuidadosamente en futuras investigaciones para garantizar que los avances en Machine Learning se traduzcan en beneficios tangibles para los pacientes.

Las perspectivas futuras en este campo apuntan hacia el desarrollo de modelos multimodales que integren diversas fuentes de información, como datos genómicos, biomarcadores sanguíneos y variables de estilo de vida. Este enfoque holístico podría superar las limitaciones de los modelos actuales y ofrecer predicciones más precisas y personalizadas. Paralelamente, resulta crucial fomentar la colaboración internacional para crear bases de datos más diversas y representativas, así como para establecer protocolos estandarizados que faciliten la implementación clínica de estas tecnologías.

En conclusión, si bien los algoritmos de Machine Learning muestran un potencial extraordinario para transformar el diagnóstico y pronóstico de la demencia, su implementación exitosa requerirá superar importantes desafíos técnicos, éticos y logísticos. El equilibrio entre innovación tecnológica y aplicabilidad clínica será fundamental para garantizar que estos avances beneficien equitativamente a todos los sectores de la población.

*Conclusiones El presente estudio realizó una ardua investigación sobre los algoritmos de Machine Learning

aplicados a la predicción de demencia, siguiendo la metodología PRISMA para garantizar rigor científico. Tras analizar 15 artículos seleccionados mediante criterios estrictos, se identificó que los algoritmos más utilizados son Random Forest, SVM, k-NN, Regresión Logística, Factorización Matricial y Redes Neuronales Convolucionales (CNN). Estos modelos demostraron una alta eficacia, con precisiones que superan el 85 % en la mayoría de los casos. Las CNN destacaron especialmente en el procesamiento de neuroimágenes, alcanzando hasta un 99 % de precisión, lo que resalta su potencial para un diagnóstico temprano y preciso.

Esta investigación contribuye significativamente al campo de la inteligencia artificial en salud al sintetizar evidencia actualizada sobre el rendimiento de estos algoritmos. Los resultados subrayan su capacidad para analizar datos complejos y multimodales, como imágenes médicas, variables clínicas y biomarcadores genéticos, ofreciendo herramientas prometedoras para la detección temprana de la demencia. Sin embargo, también se identificaron desafíos críticos, como la falta de estandarización en los conjuntos de datos y la limitada interpretabilidad de modelos avanzados como los basados en Deep Learning, lo cual puede dificultar su implementación clínica.

Como perspectivas futuras, se recomienda desarrollar modelos multimodales que integren diversas fuentes de información, como datos genómicos, biomarcadores sanguíneos y hábitos de vida, para mejorar la precisión predictiva. Además, es crucial fomentar colaboraciones internacionales que permitan recopilar datos más diversos y representativos, especialmente de poblaciones subestudiadas como las de Latinoamérica y África. Otra línea importante es la investigación en técnicas de explicabilidad (XAI) para hacer los modelos más transparentes y accesibles para los profesionales de la salud. Finalmente, se sugiere validar estos algoritmos en entornos clínicos reales, con el fin de asegurar su utilidad práctica y facilitar su adopción en sistemas de salud. Estos avances no solo optimizarían el diagnóstico y pronóstico de la demencia, sino que también podrían extenderse a otras áreas de la medicina, marcando un hito en la aplicación de la inteligencia artificial para mejorar la calidad de vida de los pacientes.

*Contribución de Autoría Ricardo Dario Mendoza Rivera: [Visualización](#), [Validación](#), [Redacción - borrador original](#). Lecca Rengifo Maria Alexandra: [Investigación](#), [Escritura](#), [revisión y edición](#). Guido Haro Marco Lucas: [Conceptualización](#), [Investigación](#), [Metodología](#). Cruz Ulloa Leydi Marisol: [Análisis formal](#), [Redacción - borrador original](#). Huamanchumo Gordillo Alexander Saul: [Redacción - borrador original](#), [Conceptualización](#), [Escritura](#), [revisión y edición](#). Quispe Sanchez Edward Steven: [Supervisión](#), [Administración de proyectos](#), [Curación de datos](#).

Referencias

- [1] A. Javeed, A. L. Dallora, J. S. Berglund *et al.*, “Machine learning for dementia prediction: A systematic review and future research directions,” *Journal of Medical Systems*, vol. 47, no. 17, 2023.
- [2] S. Grueso and R. Viejo-Sobera, “Machine learning methods for predicting progression from mild cognitive impairment to alzheimer’s disease dementia: a systematic review,” *Alzheimer’s Research & Therapy*, vol. 13, no. 162, 2021.
- [3] S. Kumar, I. Oh, S. Schindler, A. M. Lai, P. R. O. Payne, and A. Gupta, “Predicting the risk of alzheimer’s disease progression using ehr data: A multisite study,” *JAMIA Open*, vol. 4, no. 3, 2021.
- [4] A. L. Dallora, S. Eivazzadeh, E. Mendes, J. Berglund, and P. Anderberg, “Machine learning and micro-simulation techniques on the prognosis of dementia: A systematic literature review,” *PLoS ONE*, vol. 12, no. 6, 2017.
- [5] L. J. Sandoval, “Algoritmos de aprendizaje automático para análisis y predicción de datos,” *Revista Tecnológica*, no. 11, 2018.
- [6] C. Russo, H. Ramón, N. Alonso, B. Cicerchia, L. Esnaola, and J. P. Tessore, “Tratamiento masivo de datos utilizando técnicas de machine learning,” 2016.
- [7] S. M. Gutiérrez, L. A. Reséndiz, and M. G. López, “Machine learning y redes neuronales artificiales para predicción y prevención de trastorno depresivo,” *Transformación Digital de las Instituciones Educativas*, vol. 122, 2022.
- [8] G. Kantayeva *et al.*, “Application of machine learning in dementia diagnosis: A systematic literature review,” *Heliyon*, vol. 9, no. 11, 2023.
- [9] M. J. Page *et al.*, “The prisma 2020 statement: An updated guideline for reporting systematic reviews,” *Journal of Clinical Epidemiology*, vol. 134, pp. 178–189, 2021.
- [10] G. B. Morales, “Análisis de prisma como metodología para revisión sistemática: una aproximación general,” *Saúde em Redes*, vol. 8, no. sup1, pp. 339–360, 2022.