



REVISTA MÉDICA CLÍNICA LAS CONDES

<https://www.journals.elsevier.com/revista-medica-clinica-las-condes>

REVISIÓN / REVIEW

Inteligencia artificial aplicada al cuidado del ataque cerebrovascular: una descripción del estado del arte y expectativas futuras

Artificial Intelligence Applied to Stroke Care: A Description of the State of the Art and Future Expectations

Esteban Basáez-Miranda, MD^{a,b}✉

^a Departamento de Neurología, Clínica Las Condes. Santiago, Chile.

^b Facultad de Medicina, Universidad Finis Terrae. Santiago, Chile.

INFORMACIÓN DEL ARTÍCULO

Historia del Artículo:

Recibido: 14/04/2025

Aceptado: 17/06/2025

Keywords:

Stroke; Artificial Intelligence; AI.

Palabras clave:

ACV; Ataque Cerebrovascular; Inteligencia Artificial; IA; Ictus.

RESUMEN

El ataque cerebro vascular (ACV) es la segunda causa de muerte y la primera causa de discapacidad en Chile. Dado el comportamiento epidemiológico de nuestro país, se proyecta que las cifras de pacientes con ACV siga aumentando en el futuro, por lo que es imprescindible contar con nuevas estrategias de salud pública para hacer frente a ese escenario de gran carga de atención en salud. Es así como la inteligencia artificial se convierte en una herramienta de enorme utilidad en el manejo del ACV en sus distintas etapas (detección, manejo, prevención tanto primaria como secundaria, y rehabilitación). Desde una forma narrativa se describen las diferentes modalidades de inteligencia artificial y sobre sus bases, se exponen las diversas aplicaciones plasmadas en distintos trabajos clínicos según las diferentes fases del ACV. Finalmente, se exploran potenciales y proyecciones, así como las perspectivas futuras y los desafíos éticos, técnicos y de políticas de salud pública asociados.

ABSTRACT

Stroke is the second leading cause of death and the first cause of disability in Chile. Given the epidemiological behavior of our country, it is projected that the number of stroke patients will continue to increase in the future, so it is essential to have new public health strategies to address this scenario of high healthcare burden. Artificial intelligence has thus become an extremely useful tool in the management of stroke in its different stages (detection, management, primary and secondary prevention, and rehabilitation). In a narrative way, the different modalities of artificial intelligence are described and, based on their foundations, applications are presented as shown in various clinical works according to the different phases of stroke. Finally, potentials and projections are explored, along with future perspectives and the associated ethical, technical, and public health policy challenges.

✉ Autor para correspondencia

Correo electrónico: ebasaez@clinicalascondes.cl

<https://doi.org/10.1016/j.rmcl.2025.06.007>

e-ISSN: 2531-0186/ ISSN: 0716-8640/© 2025 Revista Médica Clínica Las Condes.

Este es un artículo Open Access bajo la licencia CC BY-NC-ND

(<http://creativecommons.org/licenses/by-nc-nd/4.0/>).



INTRODUCCIÓN

El ataque o accidente cerebro vascular (ACV) sigue siendo la segunda causa principal de muerte y una de las principales causas de discapacidad permanente en adultos^{1,2}. La carga económica asociada es sustancial, con costos directos e indirectos que ascienden a más de US\$890 mil millones, equivalente al 0,66% del producto interno bruto (PIB) mundial². En este contexto, la implementación efectiva de tecnologías emergentes como la inteligencia artificial (IA) ofrece un potencial significativo para transformar el paradigma actual de atención al ACV.

El presente trabajo desea, desde una visión narrativa, entregar elementos para entender la IA desde sus fundamentos, pasando a la aplicabilidad práctica en la medicina y específicamente en el campo de ACV, describiendo usos actuales y potenciales en el futuro.

METODOLOGÍA

Se realizó una revisión de la literatura científica utilizando las principales bases de datos biomédicas y tecnológicas para identificar estudios relevantes sobre la aplicación de IA en el ACV. La búsqueda se ejecutó en PubMed/MEDLINE; Web of Science, plataforma multidisciplinaria que abarca literatura científica en medicina, ingeniería y tecnología con cobertura global; y IEEE Xplore Digital Library, repositorio especializado en ingeniería eléctrica, electrónica, ciencias de la computación e innovación tecnológica en salud. La estrategia de búsqueda combinó términos MeSH y palabras clave relacionadas con "stroke", "cerebrovascular accident", "artificial intelligence", "machine learning", "deep learning" y "neural networks", aplicando filtro temporal de los últimos 10 años y filtro de idioma a español e inglés.

FUNDAMENTOS DE LA INTELIGENCIA ARTIFICIAL (IA)

La IA se define como la capacidad de las máquinas para realizar tareas que típicamente requieren inteligencia humana, como el razonamiento, el aprendizaje, la planificación y la creatividad³. El campo de la IA ha experimentado un crecimiento exponencial en las últimas décadas, impulsado por avances significativos en capacidad computacional, disponibilidad de datos y librerías disponibles⁴.

Principales tecnologías de IA en Medicina

Aprendizaje automático (machine learning)

El aprendizaje automático constituye un subconjunto de la IA que permite a los sistemas aprender y mejorar a partir de la experiencia (datos) sin ser explícitamente programados. Los algoritmos de aprendizaje automático se pueden categorizar en:

- **Aprendizaje supervisado:** En este método, se le "entrega" al modelo un conjunto de datos etiquetados de-

talladamente, de tal modo que pueda realizar tareas de clasificación o predicción con nuevos datos no conocidos. En la práctica, los operadores utilizan grandes volúmenes de datos discretos y clasificados que son utilizados como entrada de distintos modelos matemáticos como, por ejemplo, regresión lineal, regresión logística, árboles de decisión y máquinas de soporte vectorial, entregando un resultado probabilístico de la variable que se desea predecir. Los resultados obtenidos son evaluados con las etiquetas verdaderas y se calcula una función de pérdida que guía la optimización matemática. En este punto se sigue iterando en un loop de ensayo y error hasta lograr un punto de máximo rendimiento del modelo⁵.

- **Aprendizaje no supervisado:** Identifica patrones ocultos o estructuras en datos no etiquetados, sin contar con resultados predefinidos que guíen el entrenamiento. En este método, el operador entrega a los algoritmos grandes volúmenes de datos sin clasificación previa, y los modelos son capaces de agrupar la información según similitudes o características comunes que descubren automáticamente. Como ejemplo práctico, podría entregarse a estos algoritmos una gran base de datos de pacientes que han sufrido ACV, y el sistema podría identificar subgrupos de pacientes con perfiles de riesgo similares, incluyendo combinaciones de factores que previamente no habían sido consideradas como patrones relevantes⁶. Otro ejemplo sería analizar una extensa colección de imágenes cerebrales de pacientes con ACV, donde el algoritmo podría reagruparlas según características radiológicas sutiles, revelando subtipos que no eran evidentes para el análisis clínico convencional⁷.
- **Aprendizaje por refuerzo:** En este enfoque, un agente artificial aprende a tomar decisiones óptimas a través de la interacción continua con su entorno, recibiendo señales de recompensa o penalización según el resultado de sus acciones. A diferencia del aprendizaje supervisado, no requiere datos etiquetados previamente, sino que el algoritmo descubre por sí mismo la estrategia óptima mediante un proceso de prueba y error sistemático. En medicina, este enfoque ha demostrado particular utilidad en la optimización de protocolos de tratamiento personalizados, como la dosificación adaptativa de medicamentos o la personalización de regímenes de rehabilitación física. Por ejemplo, el sistema puede ajustar automáticamente la intensidad y duración de ejercicios de fisioterapia según la respuesta individual del paciente, recibiendo "recompensas" cuando se observan mejoras funcionales y "penalizaciones" cuando el progreso se estanca. Este paradigma de aprendizaje basado en retroalimentación tiene paralelos

interesantes con los mecanismos de adaptación observados en sistemas biológicos, donde las respuestas exitosas tienden a reforzarse mientras que las no exitosas se modifican o eliminan. Este enfoque es clínicamente muy útil para tareas repetitivas y con refuerzos constantes, por ejemplo, en terapias de rehabilitación⁸.

Aprendizaje profundo (deep learning)

Representa una evolución avanzada del aprendizaje automático, basada en redes neuronales artificiales de múltiples capas ocultas ("profundo"). Inspirado en la arquitectura del sistema nervioso central, este enfoque utiliza redes de neuronas artificiales interconectadas organizadas en capas. Los datos de entrada son procesados secuencialmente a través de estas capas, donde cada una extrae características cada vez más complejas y abstractas de la información original. Esta arquitectura multicapa permite al sistema aprender representaciones de datos de forma automática y generar modelos significativamente más sofisticados que los métodos tradicionales de aprendizaje automático.

El aprendizaje profundo requiere grandes volúmenes de datos para entrenar efectivamente sus múltiples parámetros y alcanzar su máximo potencial. Esta característica lo convierte en una herramienta especialmente valiosa para el análisis de imágenes médicas complejas, donde ha demostrado rendimiento excepcional en la interpretación de tomografías computarizadas (TC) y resonancias magnéticas (RM) para el diagnóstico y caracterización del ACV, superando en muchos casos la precisión del análisis humano tradicional⁹. Las principales arquitecturas del aprendizaje profundo incluyen:

-Redes Neuronales Convolucionales (CNN): Son un tipo especializado de red neuronal artificial diseñada específicamente para procesar datos que tienen una estructura espacial, como las imágenes. Su funcionamiento se basa en la operación matemática llamada "convolución", donde filtros o "*kernels*" pequeños procesan sistemáticamente la imagen, detectando características específicas como bordes, texturas y otros distintos tipos de patrones. Estos filtros actúan como detectores especializados: las primeras capas identifican características simples (líneas horizontales, verticales, curvas), las capas intermedias reconocen formas más complejas (círculos, esquinas, texturas específicas), y las capas finales combinan toda esta información para reconocer objetos completos o patrones complejos. Lo que distingue a las CNN de otras redes neuronales es su capacidad de preservar la información espacial de los datos de entrada mientras reduce progresivamente su tamaño mediante operaciones de "*pooling*", lo que les permite ser computacionalmente eficientes y muy efectivas para tareas de reconocimiento de imágenes, desde identificar objetos en fotografías hasta detectar anomalías en imágenes médicas como radiografías o tomografías.

-Redes Neuronales Recurrentes (RNN): Son un tipo de red neuronal diseñada para procesar secuencias de datos donde el orden y la relación temporal son fundamentales, como analizar el historial médico de un paciente a lo largo del tiempo o interpretar señales fisiológicas continuas, como en un electroencefalograma (EEG). A diferencia de las redes neuronales tradicionales que procesan cada entrada de forma independiente, las RNN poseen una "memoria interna" que les permite recordar información de entradas anteriores mientras procesan la entrada actual. Como en medicina, la serie de tiempo de un historial médico no solo considera los síntomas actuales, sino que también relaciona y conecta esta información con las consultas previas, los tratamientos administrados y la respuesta del paciente a lo largo del tiempo. De manera similar, las RNN procesan cada elemento de una secuencia (como cada latido cardíaco en un electrocardiograma (ECG) o cada valor de presión arterial en un monitoreo continuo) mientras mantienen un "estado interno" que preserva información relevante de los datos previos, permitiéndoles detectar patrones temporales complejos, tendencias progresivas y anomalías que solo se hacen evidentes cuando se analiza la evolución completa de los datos a lo largo del tiempo. Esta capacidad de mantener dependencias temporales las hace ideales para tareas como el procesamiento de lenguaje natural en registros médicos, análisis de señales como ECG o EEG, predicción de series temporales de parámetros vitales, y cualquier aplicación donde el contexto secuencial y la evolución temporal de los datos sean fundamentales para obtener resultados precisos¹⁰.

-Procesamiento del lenguaje natural (NLP)

Es una técnica computacional para realizar distintos tipos de tareas procesando una secuencia de caracteres, como lo es el lenguaje humano. Este es el mecanismo que opera cuando un programa sugiere la siguiente palabra dada la ingresada previamente, en los correctores ortográficos o cuando grandes modelos de lenguaje (*Large Language Models* o LLM) como GPT o Gemini reciben como entrada consultas en lenguaje natural y devuelven una respuesta en lenguaje humano comprensible. En esencia, el NLP actúa como un sofisticado "traductor" bidireccional entre el lenguaje humano y el lenguaje de las máquinas.

Su aplicación médica abre posibilidades transformadoras, especialmente considerando que tradicionalmente se ha asumido que los datos no estructurados o no tabulados representan información "perdida" para el análisis. Mediante NLP aplicado a grandes volúmenes de datos médicos, es posible realizar tareas críticas como la extracción automática de información relevante de historias clínicas electrónicas, identificando diagnósticos, tratamientos, evolución clínica y resultados que previamente requerían revisión manual exhaustiva.

Esta automatización representa un avance significativo para el manejo del ACV, donde organizaciones como la World Stroke Organization han promovido durante años el uso de algoritmos clínicos estandarizados y sistemas de indicadores de calidad que permiten la certificación de centros especializados en ACV. El NLP facilita tanto la entrada como la extracción automatizada de estos datos e indicadores desde las fichas electrónicas, optimizando los procesos de monitoreo de calidad y cumplimiento de protocolos. Esta capacidad, integrada con otras modalidades de IA, representa la base para el desarrollo de sistemas de apoyo clínico más sofisticados.

-Sistemas basados en reglas y sistemas expertos

Son sistemas automáticos basados en reglas lógicas. En términos prácticos, estos sistemas digitales replican y automatizan los "árboles de decisiones" que los médicos utilizan rutinariamente en los algoritmos de manejo clínico. Al igual que cuando seguimos un protocolo clínico paso a paso —evaluando síntomas, interpretando exámenes y eligiendo el siguiente curso de acción según guías establecidas— estos sistemas informáticos pueden ejecutar automáticamente estas mismas secuencias lógicas de decisión. La ventaja radica en que pueden procesar simultáneamente múltiples variables clínicas, aplicar consistentemente las guías de práctica clínica que previamente hemos programado en el sistema, y generar recomendaciones de manejo en tiempo real. Por ejemplo, al ingresar los datos de un paciente con sospecha de ACV —tiempo de inicio de síntomas, escala de ACV del *National Institute of Health* (NIHSS), resultados de neuroimagen, contraindicaciones para trombólisis— el sistema puede evaluar automáticamente la elegibilidad para diferentes tratamientos y sugerir el protocolo más apropiado según las guías actualizadas. Esto no solo agiliza la toma de decisiones en situaciones críticas donde el tiempo es fundamental, sino que también ayuda a estandarizar la atención y reducir la variabilidad en el manejo clínico entre diferentes profesionales y centros de salud¹¹.

Ya teniendo en mente las distintas formas de IA y la forma en que el personal asistencial clínico puede interactuar con ella, es más fácil visualizar en qué tareas y procesos estas herramientas pueden tomar un rol fundamental.

En el caso específico del ACV encontramos una patología con características muy particulares como:

- Ser una patología de alta incidencia y prevalencia
- Tener síntomas de presentación que pueden ser muy diversos y a veces difíciles de reconocer
- Ser una patología tiempo dependiente: mientras más precoz sea su reconocimiento y más rápida sea la toma de decisiones, mejor será el resultado funcional del paciente
- El hecho de que existen guías clínicas bien definidas y universales, para todo el proceso de la enfermedad.

Por ello existen varios ejemplos de cómo las distintas formas de IA se están aplicando en las distintas fases de la enfermedad. A continuación, se irán detallando y ejemplificando algunas de ellas.

INTELIGENCIA ARTIFICIAL APLICADA EN LAS DISTINTAS ETAPAS DEL ACV

El diagnóstico rápido y preciso es fundamental en el manejo del ACV, donde por mucho tiempo se ha usado la útil y concreta frase "el tiempo es cerebro". La ventana terapéutica limitada para intervenciones como la trombólisis o la trombectomía mecánica hace que la velocidad y precisión diagnóstica sean particularmente críticas¹².

En este escenario, la identificación temprana de síntomas de ACV en el entorno prehospitalario puede reducir significativamente uno de los indicadores de salud más importantes que se utilizan, que es el "tiempo puerta - aguja" (tiempo que transcurre entre el ingreso del paciente a un recinto asistencial y el momento en que efectivamente se le administra el agente trombolítico endovenoso). Las aplicaciones de IA en este contexto incluyen:

• **Sistemas de optimización de triage para paramédicos.** En un estudio retrospectivo publicado en *Stroke* 2021, se usaron las notas clínicas de los paramédicos de 965 pacientes atendidos por el sistema prehospitalario de Chicago y otros 17 centros regionales de ACV. De ellos, 580 tuvieron finalmente un diagnóstico clínico de ACV. De este total, se analizó un 70% mediante un modelo de procesamiento de lenguaje natural (NPL) y el otro 30% se analizó mediante un modelo basado en la aplicación de escala de Cincinnati y 3I-SS score. Comparando ambos métodos, el modelo de NPL fue nominalmente superior, pero sin superioridad estadística que el de Cincinnati y 3I-SS para la identificación de pacientes con ACV (0,73 [95% CI, 0,67-0,79] versus 0,67 [95% CI, 0,61-0,73], $P=0,165$)¹³. Si bien este estudio tiene limitaciones metodológicas como el número de registros y la ubicación geográfica de los pacientes y centros, genera espacio a nuevos estudios que exploren el NPL para optimizar el despacho de pacientes a centros primarios de ACV.

• **Aplicaciones móviles de detección de ACV:** Se ha explorado también el uso de aplicaciones para apoyo de triage telefónico para aumentar la sensibilidad a un ACV por oclusión de grandes vasos. En un estudio publicado el 2021¹⁴ se utilizó una aplicación para teléfonos inteligentes que transmitía en línea información al personal de despacho de ambulancia, combinado con la escala FAST, entregó un 82% de sensibilidad con un 78% de especificidad para la correcta detección de oclusión de grandes vasos, y aumentó en consecuencia la correcta derivación a un centro de alta complejidad.

Respecto al análisis de imágenes, esta es quizás el área donde la IA ha mostrado mayor impacto en el diagnóstico del ACV. Algunos de los ejemplos más notables son:

- **Detección automatizada de hemorragia intracraneal:**

En el estudio de 2018 de Chan et al.¹⁵ se usaron imágenes de 10 159 TAC de cerebro para entrenar una red neuronal convolucional para la detección de hemorragia; primero en una forma retrospectiva, y en una segunda etapa en forma prospectiva. La sensibilidad para hemorragia cerebral llegó a un 97,5% con una especificidad del 79,3%.

- **Análisis de perfusión cerebral:** Existen varios modelos que automatizan la interpretación de estudios de perfusión por TC, identificando áreas de penumbra isquémica susceptibles de reperfusión. El año 2018 se publicaron dos ensayos clínicos controlados^{16,17} que utilizaron el software RAPID para evaluar área de penumbra cerebral isquémica. Los pacientes con penumbra isquémica significativa (definida como un volumen inicial del infarto menor de 70 ml, una proporción del volumen de tejido isquémico/volumen inicial del infarto de 1,8 o más, y un volumen absoluto de isquemia potencialmente reversible de 15 ml o más) y con un tiempo de inicio de síntomas de entre 6 y 24 horas, podían ser tratados con trombectomía mecánica, en el caso de presentar una oclusión de grandes vasos cerebrales. La evolución funcional medida por escala de Rankin a los tres meses fue significativamente mejor en el grupo de pacientes tratados con trombectomía comparados con el grupo de tratamiento médico, lo que generó un cambio muy importante al ampliar la ventana terapéutica de los pacientes con ACV hasta las 24 horas.

- **Predicción de transformación hemorrágica:** existen varios estudios en que se combina información de imágenes e información clínica para predecir el riesgo de transformación hemorrágica. Por ejemplo, en el estudio de Jiang et al. 2023¹⁸, se analizaron imágenes de RM de cerebro de 338 pacientes sometidos a trombectomía mecánica, mediante un modelo de redes neuronales convolucionales. Se compararon dos modelos con análisis uniparamétrico y multiparamétrico, logrando el segundo un valor predictivo positivo de 0,658 en el modelo multivariable.

Posterior a la etapa hiperaguda del ACV, generalmente se intenta establecer la etiología del ACV isquémico. Este es un proceso crítico en la decisión de la terapia de prevención secundaria que se le indicará al paciente. Al respecto, existen varios ejemplos de trabajos de IA aplicada a esta tarea:

- **Etiología cardioembólica:** Los algoritmos de *machine learning* han demostrado capacidad superior para la identificación

automatizada de subtipos etiológicos específicos de ACV isquémico. En el estudio de Guan et al. del 2021¹⁹ se utilizaron datos clínicos de la ficha electrónica de 1598 pacientes del Massachusetts General Hospital Ischemic Stroke Registry, de los cuales 1068 presentaban características ecocardiográficas altamente compatibles con una fuente cardioembólica del ACV. El sistema integró 11 características ecocardiográficas derivadas automáticamente con un valor predictivo positivo promedio de 95% (rango 88%-100%), identificando fibrilación auricular, edad, miocardiopatía dilatada, insuficiencia cardíaca congestiva, foramen oval permeable, calcificación del anillo mitral e infarto del miocardio reciente como variables más discriminatorias. El modelo predictivo alcanzó una precisión de 92,2% (AUC = 91,1%, IC 95%: 87,5%-93,9%).

- **Reclasificación etiológica de ESUS y detección de fibrilación auricular paroxística:** Los algoritmos de *machine learning* han revolucionado la identificación de fibrilación auricular oculta en pacientes con accidente cerebrovascular embólico de fuente indeterminada (ESUS, por sus siglas en inglés). Un modelo de *machine learning* aplicado a 580 casos de ESUS²⁰ demostró que 44% (IC 95%: 39%-49%) de estos casos probablemente resultaron de embolia cardíaca, con la probabilidad individual de fuente cardioembólica significativamente asociada con detección eventual de fibrilación auricular (OR por cada 10% de aumento: 1,27, IC 95%: 1,03-1,57; c-statistic: 0,68). Se ha demostrado también que el monitoreo cardíaco prolongado con registradores implantables ha confirmado la importancia de la duración de vigilancia²¹, detectando fibrilación auricular oculta en 20,4% de pacientes ESUS durante una mediana de seguimiento de 1051 días (RIC: 478-1 287). Los modelos predictivos que integran variables clínicas y ecocardiográficas (edad, HDL-C, frecuencia cardíaca de ingreso, velocidad pico de onda A mitral y volumen auricular izquierdo) han alcanzado un AUC de 0,736-0,737 para identificar pacientes con alta probabilidad de fibrilación auricular no diagnosticada, superando significativamente la práctica estándar y facilitando estrategias de monitoreo personalizado²².

- **Análisis avanzado de placa carotídea mediante deep learning:** Los algoritmos de aprendizaje profundo han transformado la caracterización no invasiva de placas carotídeas vulnerables, superando significativamente las limitaciones de los métodos convencionales. En ultrasonido carotídeo, un modelo basado en redes neuronales convolucionales de 13 capas²³ demostró una precisión de 89,7% y AUC de 0,91 ($p < 0,0001$) para clasificar placas sintomáticas versus asintomáticas, utilizando características de distribución de escala de grises. El modelo Faster R-CNN con ResNet-50 aplicado a 5 611 imágenes de ultrasonido carotídeo multicentro alcanzó sensibilidad de 94%, especificidad de 71% y AUC de 0,91 para

detección de placas vulnerables²⁴. En otro estudio que utiliza imágenes de angio-TC carotídea, algoritmos de *machine learning* que integran composición de placa (volúmenes de lípido, hemorragia intraplaca, calcio) con grado de estenosis²⁵ lograron AUC de 0,89 para identificar placas sintomáticas, superando significativamente el análisis tradicional basado únicamente en grado de estenosis (AUC: 0,51, $p < 0,001$).

Ya entrando en la fase de rehabilitación, se debe mencionar que la carga de rehabilitación entregada al paciente, sobre todo en las fases más agudas del ACV, es uno de los factores que determina fuertemente el resultado funcional a largo plazo. En los grandes ensayos clínicos se mide con escala de Rankin modificada medida a los 3 y 6 meses posterior al ACV. Por este motivo, se busca entregar experiencias de rehabilitación lo más sostenidas en el tiempo y personalizadas, considerando también una monitorización recurrente de los logros alcanzados, para orientar mejor la rehabilitación y sobre todo sustentar la motivación en el tiempo.

Existen estudios que han demostrado la utilidad del análisis de marcha usando dispositivos de sensores de movimiento y medidas anatómicas de los pacientes, para generar un análisis de marcha. Específicamente, el 2021 Schwartz et al.²⁶ comunican un estudio en el cual se miden variables de 28 pacientes que sufrieron un ACV, considerando medidas biométricas (tamaño de cabeza, esternón, sacro, brazos superiores, antebrazos, manos, hombros, muslos, piernas inferiores y pies) y cruzándolo con datos de análisis de marcha propiamente tal en 10 metros (velocidad total de recorrido, cantidad de pasos, angulación articular de caderas, rodillas, entre otros). Ambos sets de datos se compararon contra población normal, logrando identificar factores como el largo del paso y velocidad de recorrido de 10 y 6 metros en forma lineal, con el pronóstico funcional del paciente. En suma, el mayor aporte de este estudio es abrir la posibilidad de análisis de marcha con sensores simplificados, como un predictor importante de recuperación funcional en pacientes que han sufrido un ACV.

DESAFÍOS Y CONSIDERACIONES ÉTICAS

La implementación de soluciones basadas en IA en el manejo del ACV enfrenta numerosos desafíos técnicos, clínicos, regulatorios y éticos que deben abordarse para una traslación efectiva a la práctica clínica. Por un lado, hay que considerar limitaciones técnicas y metodológicas, que van desde la adquisición hasta el almacenamiento y procesamiento de una enorme cantidad de datos. Esto requiere sistemas de registro avanzados, incluyendo un alto grado de digitalización en salud y sistemas informáticos del alto desarrollo. Además, debe existir un alto grado de inte-

gración entre los profesionales de la salud que dan la atención clínica y los centros informáticos. Particularmente en Chile, este nivel de integración solo se encuentra en centros de salud asociados a universidades. Existe un gran desafío logístico y técnico para los próximos años²⁷.

También se deben considerar aspectos éticos, como el consentimiento y privacidad de los datos de salud, que están regulados como datos sensibles en nuestra legislación. Otro aspecto importante es la equidad en el acceso a las tecnologías de salud de punta, que, dada nuestra estructura de sistema de salud, geografía y otras particularidades, pueden convertirse en una barrera significativa para la implementación de estas tecnologías.

CONCLUSIONES

La integración de inteligencia artificial en el continuo asistencial del ACV representa un cambio paradigmático con potencial para transformar significativamente el diagnóstico, tratamiento agudo, rehabilitación y prevención secundaria. Los avances actuales demuestran mejoras tangibles en precisión diagnóstica, tiempos de intervención, personalización terapéutica y accesibilidad a cuidados especializados.

Sin embargo, la traslación efectiva de estas innovaciones a la práctica clínica rutinaria requiere abordar desafíos sustanciales relacionados con validación rigurosa, integración en sistemas existentes, consideraciones éticas y modelos sostenibles de implementación. La colaboración interdisciplinaria entre profesionales clínicos, científicos de datos, ingenieros, reguladores y pacientes será fundamental para maximizar beneficios mientras se minimizan riesgos potenciales.

El futuro probablemente verá una implementación progresivamente mayor de soluciones basadas en IA, evolucionando desde herramientas de apoyo a decisiones hacia sistemas más autónomos en aspectos específicos del cuidado. Esta evolución tiene el potencial de democratizar el acceso a atención especializada, reducir la variabilidad asistencial, optimizar recursos limitados y, fundamentalmente, mejorar resultados para millones de pacientes afectados por ACV globalmente.

Las expectativas incluyen sistemas predictivos cada vez más precisos para identificación de poblaciones en riesgo, plataformas integradas que coordinen toda la cadena asistencial, dispositivos adaptativos que faciliten recuperación funcional incluso en casos previamente considerados irreversibles, y modelos proactivos que transformen fundacionalmente nuestra aproximación a esta devastadora condición neurológica.

Conflicto de interés:

El autor declara no tener conflictos de intereses.

Financiamiento:

El autor declara no haber recibido financiamiento para la redacción de este manuscrito.

Declaración de uso de Inteligencia Artificial (IA):

Este artículo tuvo colaboración de diversas herramientas de IA en su redacción y revisión ortográfica.

REFERENCIAS BIBLIOGRÁFICAS

- Li XY, Kong XM, Yang CH, Cheng ZF, Lv JJ, Guo H, et al. Global, regional, and national burden of ischemic stroke, 1990-2021: an analysis of data from the global burden of disease study 2021. *EClinicalMedicine*. 2024 Jul;75:102758. doi: 10.1016/j.eclinm.2024.102758.
- Feigin VL, Brainin M, Norrving B, Martins SO, Pandian J, Lindsay P, et al. World Stroke Organization: Global Stroke Fact Sheet 2025. *Int J Stroke*. 2025;20(2):132-144. doi: 10.1177/17474930241308142.
- Russell S, Norvig P. *Artificial Intelligence: A Modern Approach*. 4th ed. Pearson; 2020.
- Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J*. 2019;6(2):94-98. doi: 10.7861/futurehosp.6-2-94.
- Sidey-Gibbons JAM, Sidey-Gibbons CJ. Machine learning in medicine: a practical introduction. *BMC Med Res Methodol*. 2019;19(1):64. doi: 10.1186/s12874-019-0681-4.
- Akyea RK, Ntaios G, Kontopantelis E, Georgiopoulos G, Soria D, Asselbergs FW, et al. A population-based study exploring phenotypic clusters and clinical outcomes in stroke using unsupervised machine learning approach. *PLOS Digit Health*. 2023;2(9):e0000334. doi: 10.1371/journal.pdig.0000334.
- Pinto A, Pereira S, Meier R, Wiest R, Alves V, Reyes M, et al. Combining unsupervised and supervised learning for predicting the final stroke lesion. *Med Image Anal*. 2021;69:101888. doi: 10.1016/j.media.2020.101888.
- Pelosi AD, Roth N, Yehoshua T, Itah D, Braun Benjamin O, Dahan A. Personalized rehabilitation approach for reaching movement using reinforcement learning. *Sci Rep*. 2024;14(1):17675. doi: 10.1038/s41598-024-64514-6.
- Lisowska A, Beveridge E, Muir K, Poole I. Thrombus Detection in CT Brain Scans using a Convolutional Neural Network. In *Proceedings of the 10th International Joint Conference on Biomedical Engineering Systems and Technologies (BIOS-TEC 2017)*: 24-33. doi: 10.5220/0006114600240033.
- Shin HC, Tenenholz NA, Rogers JK, Schwarz CG, Senjem ML, Jeffrey L, Gunter JL, et al. Medical image synthesis for data augmentation and anonymization using generative adversarial networks. *MICCAI Workshop on Simulation and Synthesis in Medical Imaging*. 2018:1-11. doi: 10.1007/978-3-030-00536-8_1
- Sun MC, Chan JA. A clinical decision support tool to screen health records for contraindications to stroke thrombolysis-a pilot study. *BMC Med Inform Decis Mak*. 2015;15:105. doi: 10.1186/s12911-015-0229-4.
- Saver JL. Time is brain--quantified. *Stroke*. 2006;37(1):263-266. doi: 10.1161/01.STR.0000196957.55928.ab.
- Mayampurath A, Parmianpour Z, Richards CT, Meurer WJ, Lee J, Ankenman B, et al. Improving Prehospital Stroke Diagnosis Using Natural Language Processing of Paramedic Reports. *Stroke*. 2021;52(8):2676-2679. doi: 10.1161/STROKEAHA.120.033580.
- Frank B, Lembeck T, Toppe N, Brune B, Bozkurt B, Deuschl C, et al. FAST-ED scale smartphone app-based prediction of large vessel occlusion in suspected stroke by emergency medical service. *Ther Adv Neurol Disord*. 2021;14:17562864211054962. doi: 10.1177/17562864211054962.
- Chang PD, Kuoy E, Grinband J, Weinberg BD, Thompson M, Homo R, et al. Hybrid 3D/2D Convolutional Neural Network for Hemorrhage Evaluation on Head CT. *AJNR Am J Neuroradiol*. 2018;39(9):1609-1616. doi: 10.3174/ajnr.A5742.
- Albers GW, Marks MP, Kemp S, Christensen S, Tsai JP, Ortega-Gutierrez S, et al.; DEFUSE 3 Investigators. Thrombectomy for Stroke at 6 to 16 Hours with Selection by Perfusion Imaging. *N Engl J Med*. 2018;378(8):708-718. doi: 10.1056/NEJMoa1713973.
- Nogueira RG, Jadhav AP, Haussen DC, Bonafe A, Budzik RF, Bhuva P, et al.; DAWN Trial Investigators. Thrombectomy 6 to 24 Hours after Stroke with a Mismatch between Deficit and Infarct. *N Engl J Med*. 2018;378(1):11-21. doi: 10.1056/NEJMoa1706442.
- Jiang L, Zhou L, Yong W, Cui J, Geng W, Chen H, et al. A deep learning-based model for prediction of hemorrhagic transformation after stroke. *Brain Pathol*. 2023;33(2):e13023. doi: 10.1111/bpa.13023.
- Guan W, Ko D, Khurshid S, Trisini Lipsanopoulos AT, Ashburner JM, Harrington LX, et al. Automated Electronic Phenotyping of Cardioembolic Stroke. *Stroke*. 2021;52(1):181-189. doi: 10.1161/STROKEAHA.120.030663.
- Kamel H, Navi BB, Parikh NS, Merkler AE, Okin PM, Devereux RB, et al. Machine Learning Prediction of Stroke Mechanism in Embolic Strokes of Undetermined Source. *Stroke*. 2020;51(9):e203-e210. doi: 10.1161/STROKEAHA.120.029305.
- Ming C, Lee GJW, Teo YH, Teo YN, Toh EMS, Li TYW, et al. Machine Learning Modeling to Predict Atrial Fibrillation Detection in Embolic Stroke of Undetermined Source Patients. *J Pers Med*. 2024;14(5):534. doi: 10.3390/jpm14050534.
- Ntaios G, Perlepe K, Lambrou D, Sirimarco G, Strambo D, Eskandari A, et al. Identification of patients with embolic stroke of undetermined source and low risk of new incident atrial fibrillation: The AF-ESUS score. *Int J Stroke*. 2021;16(1):29-38. doi: 10.1177/1747493020925281.
- Saba L, Sanagala SS, Gupta SK, Koppula VK, Johri AM, Sharma AM, et al. Ultrasound-based internal carotid artery plaque characterization using deep learning paradigm on supercomputer: a cardiovascular disease/stroke risk assessment system. *Int J Cardiovasc Imaging*. 2021;37(5):1511-1528. doi: 10.1007/s10554-020-02124-9.
- Zhang H, Zhao F. Deep Learning-Based Carotid Plaque Ultrasound Image Detection and Classification Study. *Rev Cardiovasc Med*. 2024;25(12):454. doi: 10.31083/j.rcm2512454.
- Pisu F, Williamson BJ, Nardi V, Paraskevas KI, Puig J, Vagal A, et al. Machine Learning Detects Symptomatic Plaques in Patients With Carotid Atherosclerosis on CT Angiography. *Circ Cardiovasc Imaging*. 2024;17(6):e016274. doi: 10.1161/CIRCIMAGING.123.016274.
- Schwarz A, Al-Haj Husain A, Einaudi L, Thürlimann E, Läderach J, Awai Easthope C, et al. Reliability and Validity of a Wearable Sensing System and Online Gait Analysis Report in Persons after Stroke. *Sensors (Basel)*. 2023;23(2):624. doi: 10.3390/s23020624.
- Silcox C, Zimlichmann E, Huber K, Rowen N, Saunders R, McClellan M, Kahn CN 3rd, Salzberg CA, Bates DW. The potential for artificial intelligence to transform healthcare: perspectives from international health leaders. *NPJ Digit Med*. 2024 Apr 9;7(1):88. doi: 10.1038/s41746-024-01097-6.