

<https://doi.org/10.23913/ride.v16i31.2538>

Artículos científicos

Aplicación Móvil Basada en Deep Learning para la Inclusión Educativa de Personas Sordas: Reconocimiento y Traducción de la Lengua de Señas Mexicana

Deep Learning-Based Mobile Application for the Educational Inclusion of Deaf Individuals: Recognition and Translation of Mexican Sign Language

Aplicativo Móvel Baseado em Aprendizado Profundo para a Inclusão Educacional de Pessoas Surdas: Reconhecimento e Tradução da Língua Mexicana de Sinais

René Edmundo Cuevas Valencia

Universidad Autónoma de Guerrero, México

reneecuevas@uagro.mx

<https://orcid.org/0000-0001-9528-7603>

Gabriel Alejandro Salgado Martínez

Universidad Autónoma de Guerrero, México

06316477@uagro.mx

<https://orcid.org/0009-0004-8614-5469>

Resumen

La inclusión educativa es un derecho fundamental que busca garantizar el acceso a la educación para todas las personas, incluidas aquellas con discapacidad auditiva. No obstante, la comunicación entre personas sordas y oyentes continúa representando una barrera significativa en los entornos educativos. Este estudio presenta el desarrollo de una aplicación móvil basada en algoritmos de *Deep Learning* (aprendizaje profundo), diseñada para reconocer y traducir la Lengua de Señas Mexicana (LSM) al español. Su objetivo es mejorar la interacción en el aula y promover la educación inclusiva. Se empleó la librería MediaPipe para la detección de manos, y se entrenaron modelos de Redes Neuronales Convolucionales (CNN) junto con Redes de Memoria a Largo Plazo (LSTM) utilizando TensorFlow Lite para la clasificación de señas. La aplicación permite el reconocimiento tanto de señas estáticas



como dinámicas, alcanzando una precisión superior al 90% en condiciones controladas. Los hallazgos indican que las tecnologías de aprendizaje profundo pueden ser herramientas eficaces para mejorar la comunicación en entornos educativos al permitir la interacción en tiempo real sin necesidad de conexión a internet. Sin embargo, persisten desafíos en el reconocimiento preciso de señas en condiciones de baja iluminación y durante movimientos rápidos de las manos. Los trabajos futuros, se enfocarán en optimizar el modelo para interpretar expresiones más complejas e integrar la aplicación con plataformas digitales de aprendizaje, a fin de ampliar su impacto en la educación inclusiva.

Palabras clave: aprendizaje profundo, inclusión educativa, inteligencia artificial, lengua de señas mexicana, tecnología móvil.

Abstract

Educational inclusion is a fundamental right that ensures access to education for all individuals, including those with hearing disabilities. However, communication between deaf and hearing individuals remains a significant barrier in educational settings. This study presents the development of a mobile application based on Deep Learning algorithms for the recognition and translation of Mexican Sign Language (LSM) into Spanish, with the goal of improving classroom interaction and contributing to educational inclusion. The MediaPipe library was used for hand detection, and Convolutional Neural Networks (CNN) and Recurrent Neural Networks (LSTM) models were trained in TensorFlow Lite for sign classification. The application enables the recognition of both static and dynamic signs, achieving an accuracy of over 90% under controlled conditions. The results suggest that deep learning technology can be a valuable tool for enhancing communication in educational environments, enabling real-time interaction without requiring an internet connection. However, challenges were identified in sign recognition accuracy under low-light conditions and in detecting fast movements. As future work, we propose optimizing the model to recognize complex expressions, and integrating it with digital learning platforms to expand its impact on inclusive education.

Keywords: deep learning, educational inclusion, artificial intelligence, Mexican Sign Language, mobile technology.

Resumo

A inclusão educacional é um direito fundamental que visa garantir o acesso à educação para todas as pessoas, incluindo aquelas com deficiência auditiva. No entanto, a comunicação entre surdos e ouvintes continua sendo uma barreira em ambientes educacionais. Este estudo apresenta o desenvolvimento de um aplicativo móvel baseado em algoritmos de Deep Learning para o reconhecimento e a tradução da Língua Mexicana de Sinais (LSM) para o espanhol, com o objetivo de aprimorar a interação em sala de aula e contribuir para a inclusão educacional. A biblioteca MediaPipe foi utilizada para a detecção de mãos, e os modelos de Redes Neurais Convolucionais (CNN) e Redes Neurais Recorrentes (LSTM) foram treinados no TensorFlow Lite para a classificação de sinais. O aplicativo permite a identificação de sinais fixos e móveis, alcançando uma precisão de mais de 90% em condições controladas. Os resultados sugerem que a tecnologia de deep learning pode ser uma ferramenta valiosa para aprimorar a comunicação em ambientes educacionais, permitindo a interação em tempo real sem a necessidade de conexão à internet. No entanto, foram identificados desafios na precisão do reconhecimento de sinais em ambientes com pouca luz e na detecção de movimentos rápidos. Trabalhos futuros sugerem a otimização do modelo para reconhecer expressões mais complexas e integrá-lo a plataformas digitais de aprendizagem para ampliar seu impacto na educação inclusiva.

Palavras-chave: aprendizagem profunda, inclusão educacional, inteligência artificial, Língua Mexicana de Sinais, tecnologia móvel.

Fecha Recepción: Marzo 2025

Fecha Aceptación: Julio 2025

Introducción

La educación inclusiva es un derecho fundamental que busca garantizar la igualdad de oportunidades en el acceso al conocimiento. Sin embargo, las personas sordas enfrentan barreras significativas en entornos educativos debido a la falta de estrategias de comunicación adaptadas a sus necesidades (GoMex, 2016). La Lengua de Señas Mexicana (LSM) es el medio principal de comunicación para esta comunidad, pero el desconocimiento generalizado de la LSM dificulta su integración en entornos académicos y sociales (Munguía, 2017).

Uno de los principales desafíos es la disponibilidad limitada de intérpretes de LSM en las instituciones educativas. La falta de estos profesionales restringe el acceso de los estudiantes sordos a la información, lo cual puede repercutir en su rendimiento académico y



su participación en actividades de aprendizaje. Además, los materiales educativos en LSM son escasos, lo que refuerza la necesidad de herramientas tecnológicas que faciliten la comunicación entre hablantes y no hablantes de esta lengua (Pérez & Cruz, 2021).

La carencia de herramientas accesibles para traducir la LSM al español agrava esta situación. Aunque existen iniciativas que buscan mejorar la accesibilidad, muchas de ellas se centran en entornos específicos y no están ampliamente disponibles en plataformas de uso cotidiano. Esto subraya la necesidad de desarrollar soluciones tecnológicas que permitan la interpretación en tiempo real y sean de fácil acceso para docentes, estudiantes y familias (Martínez et al., 2016).

El avance de la inteligencia artificial (IA) y el aprendizaje profundo (*Deep Learning*) han permitido el desarrollo de sistemas capaces de reconocer y traducir lenguas de señas con alta precisión. Estas tecnologías han demostrado ser efectivas en el reconocimiento de patrones visuales y el procesamiento de lenguaje natural, lo que las convierte en herramientas viables para abordar la barrera comunicativa en la educación de personas sordas (Heaton et al., 2016).

El aprendizaje profundo permite el desarrollo de modelos avanzados de reconocimiento de imágenes que pueden interpretar con precisión gestos y señas de la LSM. Este enfoque ha sido implementado en estudios previos con resultados prometedores, mejorando notablemente la exactitud de la interpretación automática de lenguas de señas mediante el uso de redes neuronales convolucionales y redes neuronales recurrentes (Salgado et al., 2024).

La implementación de modelos de *Machine Learning* (ML) en dispositivos móviles representa una solución innovadora para la accesibilidad educativa. Los teléfonos inteligentes y tabletas son herramientas ampliamente utilizadas que pueden convertirse en asistentes educativos para la comunidad sorda mediante aplicaciones diseñadas para traducir la LSM al español en tiempo real. Este enfoque no solo facilita la interacción en el aula, sino que también promueve la autonomía de los estudiantes sordos y su participación en distintos niveles de enseñanza (Tang, 2019).

Las aplicaciones móviles ofrecen una alternativa accesible y escalable, permitiendo que estudiantes y docentes interactúen de manera más inclusiva. Su uso en la educación inclusiva ha sido documentado en diversas investigaciones, destacando su efectividad en la reducción de barreras de comunicación y en la mejora de la experiencia de aprendizaje para personas con discapacidad auditiva (Díaz & Navarrete, 2025). La importancia de divulgar

este tipo de aplicaciones radica en su potencial para beneficiar a comunidades que realmente las necesitan, especialmente aquellas en contextos económicos desfavorecidos.

Además, la integración de estas tecnologías en la educación contribuye a la equidad digital, permitiendo que estudiantes con discapacidad auditiva accedan a los mismos recursos que sus compañeros oyentes. La posibilidad de contar con una herramienta portátil que facilite la traducción inmediata de señas amplía el acceso a contenidos educativos, promoviendo una enseñanza más personalizada y equitativa; lo anterior, aplicado al conjunto de la población, representa un aporte significativo a la inclusión social, al reducir las brechas digitales de comunicación (UNESCO, 2018).

Por consiguiente, la investigación se enfoca en el desarrollo de una aplicación móvil basada en *Deep Learning* para el reconocimiento y traducción de la LSM al español, facilitando la expresión de las personas sordas hacia su entorno educativo, con el objetivo de contribuir a la inclusión educativa de esta comunidad y fortalecer su acceso en igualdad de condiciones. Si bien la aplicación no sustituye a los intérpretes de LSM ni permite la traducción bidireccional, representa un paso importante hacia entornos más accesibles.

Estado del Arte

El reconocimiento automático de la LSM ha sido objeto de múltiples investigaciones en los últimos años, impulsadas por la necesidad de mejorar la accesibilidad educativa y la inclusión social de las personas sordas. Los estudios previos han abordado esta problemática a través del uso de diversas tecnologías, como sensores de movimiento, visión por computadora y aprendizaje automático. A continuación se describen investigaciones que se encontraron como relevantes a nivel mundial sobre el reconocimiento de lenguas de señas, en un segundo momento se aportan datos relevantes sobre la lengua de señas mexicana y en un tercer momento resaltar desarrollos aplicados con móviles.

Investigaciones previas han implementado diferentes enfoques para la interpretación de lenguas de señas, incluyendo el uso de sensores como Leap Motion, Microsoft Kinect y guantes con sensores de movimiento. Ejemplos de estos trabajos incluyen el modelo basado en K-Nearest Neighbors (KNN) utilizado para la Lengua de Señas de India (Amrutha & Prabu, 2021), el uso de Support Vector Machines (SVM) para el reconocimiento de la Lengua de Señas Americana (Halder & Tayade, 2021), y la combinación de CNN con datos de sensores electromagnéticos para la Lengua de Señas China (Wadhawan & Kumar, 2020).

A nivel internacional, también se ha explorado el uso de modelos como Hidden Markov Models (HMM) en la traducción automática de frases completas de la Lengua de Señas Americana, logrando tasas de reconocimiento de hasta el 74% en entornos controlados (Zafrulla et al., 2011) y (Makris, 2021). Sin embargo, estos enfoques han demostrado limitaciones al requerir hardware especializado y presentar dificultades en la generalización a entornos no controlados.

En México, los estudios sobre reconocimiento automático de la LSM han explorado diversas metodologías. Algunos trabajos han utilizado dispositivos Kinect para capturar el movimiento de las manos y entrenar modelos de Perceptrón Multicapa (MLP) con tasas de reconocimiento superiores al 93% en corpus de palabras comunes (Trujillo & García, 2021). Otros enfoques han empleado CNN para la clasificación de señas fijas obtenidas con cámaras convencionales, logrando precisiones cercanas al 98% en la detección de letras del alfabeto dactilológico (Rivas, 2019).

El uso de MediaPipe como herramienta de extracción de características ha ganado relevancia en estudios recientes, permitiendo la detección precisa de puntos clave de las manos sin necesidad de hardware especializado. González et al. (2024) reportó un sistema de reconocimiento de 30 señas de la LSM basado en LSTM con una precisión del 97% en entornos de prueba controlados.

El desarrollo de aplicaciones móviles para la traducción de lenguas de señas representa un área emergente dentro del campo de la accesibilidad educativa. Investigaciones previas han abordado esta problemática a través de enfoques híbridos que combinan modelos de aprendizaje profundo con optimización para dispositivos móviles mediante TensorFlow Lite.

Estudios como los de Aquino (2018) y Gallego (2021) han demostrado que el uso de CNNs en dispositivos Android e iOS permite la traducción eficiente de señas estáticas, con tasas de reconocimiento superiores al 90%. Sin embargo, la mayoría de estas aplicaciones aún presentan limitaciones en el reconocimiento de señas dinámicas, debido a restricciones computacionales en los dispositivos móviles.

En el contexto de la LSM, Maciel et al. (2016) propusieron una aplicación móvil basada en reconocimiento de imágenes mediante detección de bordes, logrando tasas de acierto del 98% con modelos de Support Vector Machines (SVM). Sin embargo, la implementación de modelos de *Machine Learning* (ML) en dispositivos móviles sigue siendo un desafío, especialmente para la interpretación en tiempo real de expresiones complejas.

El análisis de los estudios previos sugiere que, si bien los modelos de reconocimiento de lenguas de señas han logrado avances significativos, aún existen desafíos en la implementación de soluciones móviles eficientes para la LSM. El uso de modelos de *Deep Learning* en dispositivos móviles representa una alternativa prometedora para mejorar la accesibilidad, pero requiere optimización en términos de consumo energético y capacidad de procesamiento.

Marco Teórico

La inclusión educativa es un principio clave en la educación superior y se encuentra respaldada por diversas normativas internacionales y nacionales. Para Amezcua & Amezcua (2018) destacan que la accesibilidad y equidad en la educación son fundamentales para garantizar oportunidades de aprendizaje para todos los estudiantes, incluidas las personas con discapacidad auditiva. En México, la Secretaría de Educación Pública (SEP) ha impulsado políticas para la inclusión de personas sordas en instituciones educativas a través de programas que fomentan la accesibilidad y el uso de herramientas tecnológicas (Cruz & Sanabria, 2024). Investigaciones recientes han subrayado la importancia de la implementación de tecnologías digitales para la inclusión educativa, lo que permite el desarrollo de soluciones innovadoras en el aprendizaje de estudiantes con discapacidades (Screpnik, 2024).

La Lengua de Señas Mexicana (LSM) es el principal medio de comunicación de la comunidad sorda en México y desempeña un papel crucial en la adquisición del conocimiento. Su reconocimiento como una lengua oficial en el país ha permitido la implementación de estrategias para mejorar la enseñanza de personas sordas (Cruz, 2008). Sin embargo, persisten dificultades en la enseñanza de contenidos académicos para estudiantes sordos debido a la escasez de materiales educativos en LSM y la insuficiencia de intérpretes en el aula (Pérez & Cruz, 2021). Estudios recientes han demostrado que la inclusión de la LSM en programas educativos mejora significativamente la comprensión y retención de conocimientos en estudiantes sordos, lo que resalta la necesidad de materiales didácticos adaptados (Hurtado et al., 2024).

La inteligencia artificial ha transformado diversos sectores, incluida la educación. En el contexto de la inclusión educativa, el *Machine Learning* y el *Deep Learning* han demostrado ser herramientas eficaces para la detección y traducción de patrones visuales, facilitando la comunicación de personas con discapacidad auditiva (Heaton et al., 2018).

Aplicaciones previas han demostrado su utilidad en la educación, desde sistemas de tutoría hasta asistentes virtuales y traducción automática de lenguas de señas mediante visión computacional (Mejía et al., 2022). La investigación de Berrones & Salgado (2023) destacan que los modelos de inteligencia artificial aplicados a la educación inclusiva han logrado aumentar la accesibilidad en plataformas digitales y mejorar la experiencia de aprendizaje para personas con discapacidades sensoriales.

El uso de aplicaciones móviles en el aprendizaje ha crecido exponencialmente en los últimos años. Estas herramientas permiten la enseñanza adaptada a diferentes necesidades, incluyendo a personas con discapacidad auditiva. Diversos estudios han explorado el impacto de aplicaciones móviles en la educación de personas sordas, destacando su efectividad en la mejora de la comprensión del lenguaje y la comunicación con su entorno (Espejel, 2021). Además, estas herramientas favorecen el aprendizaje autónomo y el acceso inmediato a contenidos en lengua de señas, promoviendo una mayor inclusión en el ámbito educativo. Investigaciones recientes resaltan que las aplicaciones móviles diseñadas para la enseñanza de la LSM han aumentado el nivel de interacción de los estudiantes sordos con materiales de aprendizaje digital, facilitando su participación en procesos educativos (Vásquez et al., 2024).

Metodología

Respecto al diseño de la investigación, el presente estudio se basa en un enfoque cuantitativo experimental, ya que busca la precisión del sistema de reconocimiento de la Lengua de Señas Mexicana (LSM) a través de modelos de *Machine Learning* (ML) y su implementación en una aplicación móvil. Para ello, se desarrolló una metodología estructurada que incluye la recolección de datos, el desarrollo de modelos de aprendizaje profundo y la evaluación del rendimiento del sistema en distintos escenarios educativos (Salgado et al., 2024).

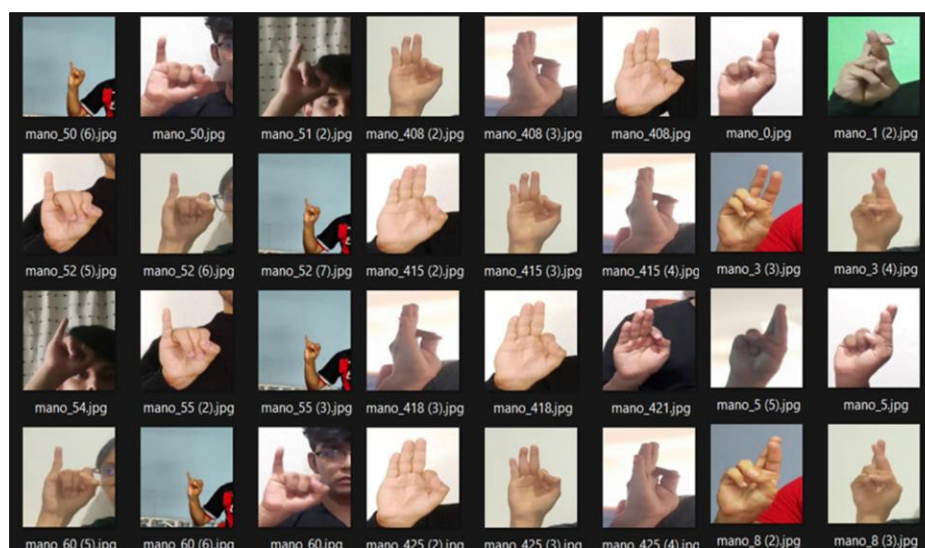
La metodología utilizada para el desarrollo de la aplicación móvil se basa en el marco SCRUM, una metodología ágil que permite la mejora progresiva del software mediante iteraciones definidas (Martín, 2020) y (Salgado, 2024). Esto permitió ajustes continuos en la aplicación conforme avanzaban las pruebas con voluntarios.

Recolección de Datos: Para el entrenamiento de los modelos de *Deep Learning*, se recopiló un conjunto de datos con imágenes y videos de señas de la LSM. El conjunto de

datos se obtuvo con la participación de estudiantes voluntarios, quienes realizaron diferentes señas en entornos controlados y con variaciones en la iluminación (Salgado, 2024).

Datos recopilados: Salgado et al. (2024) considera que 21 señas fijas de gestos corresponden al alfabeto dactilológico; 16 expresiones de uso común para señas en movimiento en la comunicación de la LSM; respecto al número de voluntarios, 8 son los participantes para las señas fijas y 10 para las señas en movimiento; además se incluye un formato de captura de secuencias de video e imágenes extraídas de cada seña. En la figura 1, se muestran ejemplos de las imágenes obtenidas.

Figura 1. Ejemplos de las imágenes de señas obtenidas.

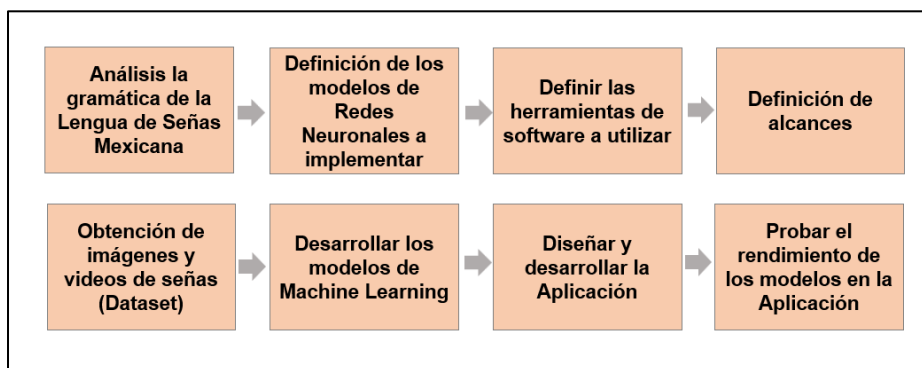


Fuente: (Salgado et al.,2024)

Los videos obtenidos fueron procesados para extraer coordenadas clave de la mano, utilizando la librería MediaPipe, con la finalidad de obtener puntos de referencia precisos en cada gesto.

Respecto al desarrollo de la aplicación móvil se trabajó mediante Android Studio y el uso de *TensorFlow Lite* para la implementación de modelos de aprendizaje automático optimizados. La aplicación permite el reconocimiento en tiempo real de señas fijas y en movimiento mediante la cámara del dispositivo. En la figura 2 se presenta el esquema general.

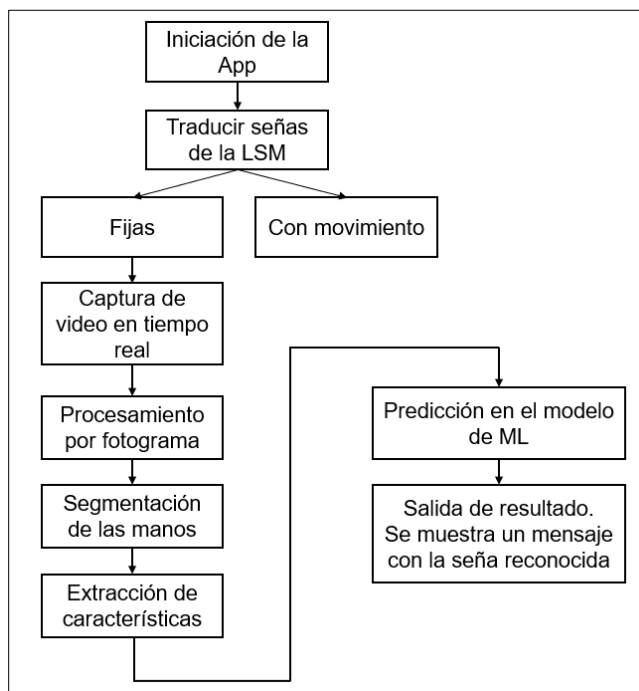
Figura 2. Esquema general propuesto.



Fuente: (Salgado,2024).

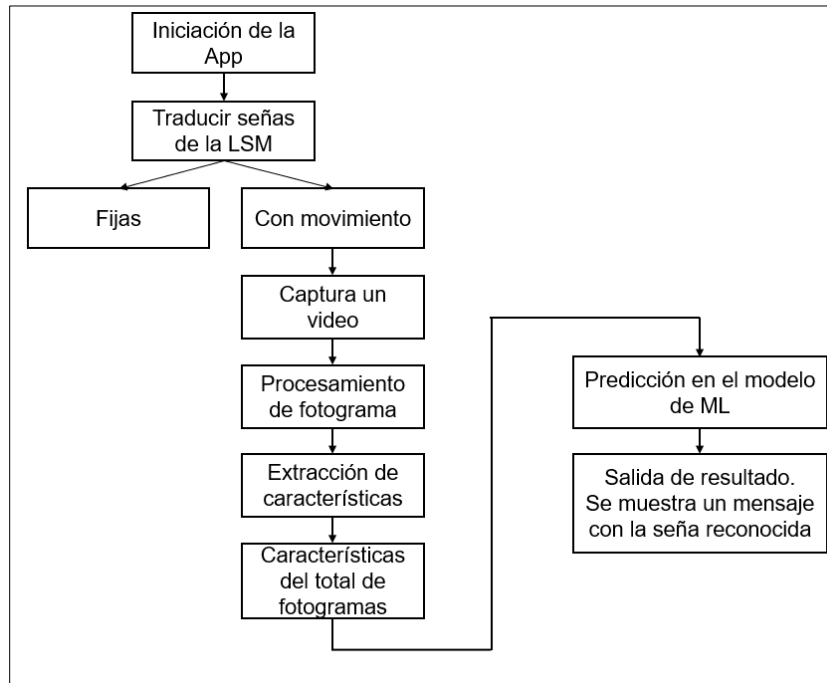
Dentro de los algoritmos utilizados, para el reconocimiento de señas, se desarrollaron modelos de CNN para la clasificación de señas fijas, así como se observa el diagrama de la figura 3 y en la figura 4 con los modelos de Redes Neuronales Recurrentes (RNN) con LSTM para la identificación de señas en movimiento y predicción de señas dinámicas, así como *MediaPipe Hands* para la extracción de puntos clave en la detección de manos.

Figura 3. Diagrama de reconocimiento de señas fijas.



Fuente: (Salgado,2024).

Figura 4. Diagrama de reconocimiento de señas en movimiento.



Fuente: (Salgado,2024).

Se realizaron pruebas del rendimiento del sistema en diferentes dispositivos y entornos para medir la precisión del reconocimiento de señas. En la tabla 1 se muestra la composición del conjunto de datos recolectado.

Tabla 1. Composición del conjunto de datos recolectado.

Seña	Cantidad de imágenes	Etiqueta
A	6,839	0
B	6,356	1
C	6,240	2
D	6,748	3
E	6,306	4
F	6,702	5
G	6,941	6
H	7,058	7
I	6,146	8
L	7,038	9
M	6,165	10
N	6,103	11
O	6,535	12
P	6,928	13
R	6,416	14
S	6,567	15
T	6,378	16
U	6,449	17
V	6,242	18
W	6,594	19
Y	7,012	20

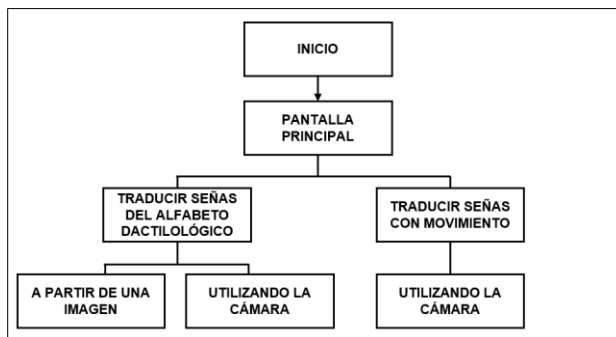
Fuente: (Salgado,2024).

Para la validación de las pruebas realizadas, las que se listan a continuación, de forma gráfica se observa en la figura 5:

1. Pruebas en diferentes condiciones de iluminación: Evaluación de la precisión del reconocimiento en entornos con variaciones de luz.
2. Comparación con otros sistemas de traducción de LSM: Se evaluó la precisión de la aplicación con respecto a herramientas previas basadas en procesamiento de imágenes.

3. Análisis del tiempo de respuesta: Medición del tiempo necesario para procesar y traducir cada seña en tiempo real.

Figura 5. Diagrama de navegación de la aplicación.



Fuente: (Salgado et al., 2024).

Para las herramientas utilizadas, el desarrollo del modelo de reconocimiento y la aplicación móvil se realizó con las siguientes:

- *Hardware*: Laptop Dell G3-3590 (Windows 11, 12 GB RAM, GPU NVIDIA GTX 1650);
- *Software y librerías*: Python (para entrenamiento de modelos); *TensorFlow* y *TensorFlow Lite*; *MediaPipe* (detección de manos y puntos clave); *OpenCV* (procesamiento de imágenes); Android Studio (desarrollo de la aplicación móvil).

La implementación de esta metodología permitió el desarrollo de un sistema de traducción de la LSM con un alto nivel de precisión, basado en modelos optimizados para su ejecución en dispositivos móviles. La combinación de aprendizaje profundo y tecnologías accesibles ofrece una solución innovadora para la educación inclusiva de personas sordas, tabla 2 lista los smartphones utilizados.

Tabla 2. Smartphones utilizados durante las pruebas.

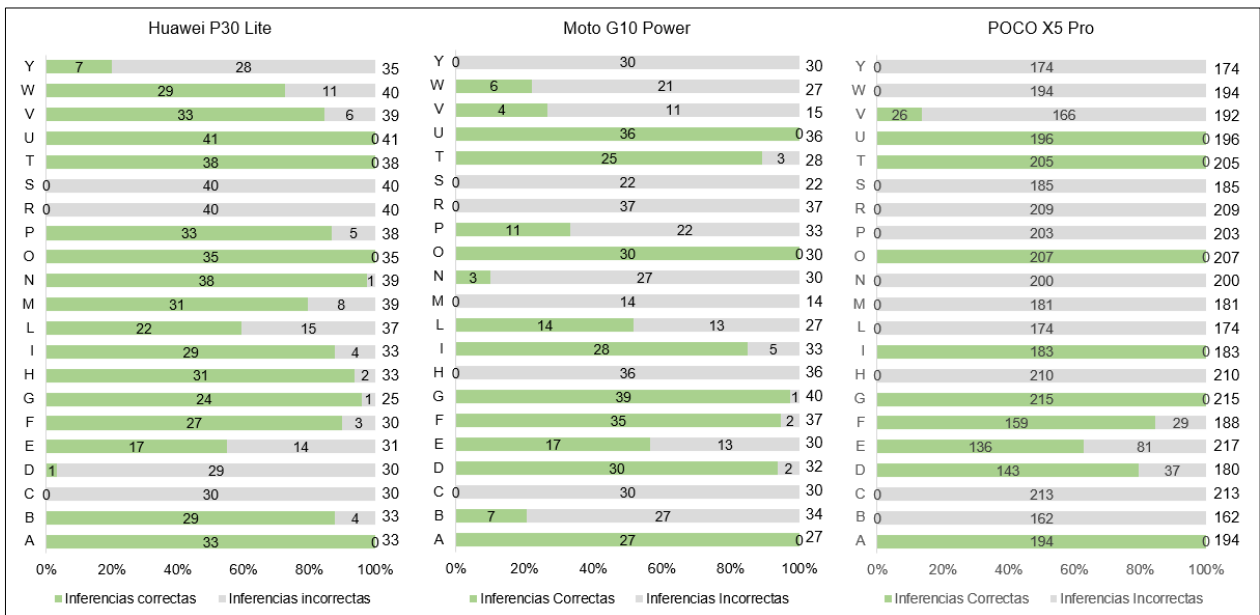
Marca	Modelo	Versión de Android	Procesador	Memoria RAM	Pantalla	Resolución	Cámara trasera
Huawei	Huawei P30 Lite (2019)	9	Kirin 710 de 2.2 GHz	4 GB	6.15"	1080 x 2312 píxeles	24 MP (principal)
Motorola	Moto G10 Power (2021)	11	Snapdragon 460 de 1.8 GHz	4 GB	6.5"	720 x 1600 píxeles	48 MP (principal)
Xiaomi	POCO X5 Pro 5G (2023)	14	Snapdragon 778G de 2.4 GHz	6 GB	6.67"	1080 x 2400 píxeles	108 MP (principal)

Fuente: (Salgado, 2024).

Resultados

El sistema de reconocimiento de señas basado en *Deep Learning* fue evaluado en distintos entornos educativos para determinar su precisión y viabilidad. Se realizaron pruebas en aulas con diferentes condiciones de iluminación y otros dispositivos móviles con el objetivo de analizar la estabilidad del modelo. En la figura 6, se muestra la comparación de la cantidad de inferencias correctas e incorrectas en cada smartphone a una distancia de 100 cm entre el dispositivo y la persona señante.


Figura 6. Comparación de la cantidad de inferencias correctas e incorrectas.



Fuente: (Salgado, 2024).

Porcentaje promedio en el reconocimiento, en la figura 7 se muestra la comparativa de los resultados de los tres dispositivos.

Figura 7. Comparación del promedio de reconocimiento por smartphone.



Fuente: (Salgado, 2024).

Los resultados indicaron que el modelo alcanzó una precisión (accuracy) del 95.3% en la clasificación de señas fijas y un 89.7% en la clasificación de señas en movimiento, valores que superan a sistemas tradicionales de reconocimiento basados en técnicas de visión por computadora sin aprendizaje profundo, como Haar cascades, HOG o SIFT (Salgado, 2024). Sin embargo, en la tabla 2, se observó una ligera disminución en la precisión cuando la iluminación era insuficiente o cuando las señas eran realizadas a una distancia superior a 1.5 metros de la cámara del dispositivo móvil. Además, en la tabla 3 se muestran los resultados de las métricas evaluadas en las arquitecturas propuestas para la red neuronal MLP para el reconocimiento de señas fijas.

Tabla 3. Resultados de las métricas para el reconocimiento de señas fijas.

Arquitectura	Accuracy	Precision	Recall	F1-Score
1	85.6494	0.8670	0.8558	0.8449
2	93.2421	0.9335	0.9313	0.9315
3	94.6321	0.9462	0.9455	0.9456
4	95.4451	0.9543	0.9537	0.9538
5	96.2835	0.9627	0.9622	0.9623

Fuente: (Salgado et al., 2024).

Discusión

Los resultados obtenidos indican que la aplicación desarrollada tiene un alto grado de precisión en el reconocimiento de la Lengua de Señas Mexicana (LSM), superando otros enfoques que dependen exclusivamente de algoritmos de visión por computadora. Estudios previos, como los realizados por Trujillo y García (2021) y Mejía et al. (2022), muestran que el uso de dispositivos especializados como Kinect o Leap Motion logran precisiones similares; sin embargo; estos enfoques requieren hardware específico, lo que limita su accesibilidad. En contraste, la aplicación propuesta permite la traducción de la LSM utilizando la cámara de un teléfono móvil, ampliando su aplicabilidad en entornos educativos y comunitarios.

Impacto en la educación inclusiva

El uso de esta aplicación móvil en entornos educativos demuestra un gran potencial para la inclusión de estudiantes sordos. Al comparar su desempeño con métodos tradicionales, como el uso de intérpretes de LSM o materiales impresos con imágenes, se observó una mejora en la autonomía del estudiante, ya que la aplicación permite la interpretación síncrona sin necesidad de apoyo externo. Estudios previos han señalado que el acceso a tecnologías inclusivas mejora la participación de estudiantes con discapacidad auditiva en entornos de aprendizaje formal (UNESCO, 2018). En este sentido, la aplicación desarrollada representa un avance significativo al brindar una herramienta accesible para la traducción de señas en tiempo real, reduciendo las barreras de comunicación en las aulas.

Limitaciones y mejoras futuras

Entre las principales limitaciones identificadas se encuentran la disminución de precisión bajo condiciones de baja iluminación y la dificultad para detectar movimientos rápidos de las manos. Para superar estos retos, se propone implementar técnicas de preprocesamiento de imagen, como la normalización del brillo y el uso de aumento de datos sintéticos, que ya han demostrado eficacia en la mejora de la generalización de modelos de visión por computadora. Asimismo, la incorporación de arquitecturas basadas en *Transformers* podría optimizar la interpretación de secuencias temporales complejas, incrementando así la precisión en el reconocimiento de señas en movimiento.

Otro desafío identificado es la aceptación y adopción de la aplicación por parte de docentes y estudiantes. Aunque el uso de dispositivos móviles en la educación es cada vez más frecuente, aún existen resistencias relacionadas con actitudes conservadoras, falta de formación tecnológica y limitaciones institucionales. Para superar estas barreras, se recomienda fortalecer la capacitación docente en el uso de la herramienta y promover su integración con plataformas de gestión del aprendizaje (LMS), como entornos virtuales que faciliten la interacción, evaluación y seguimiento del progreso estudiantil.

Una limitación importante del sistema es realizar la traducción de LSM al español, lo cual restringe la interacción bidireccional en el aula. Efectivamente, los estudiantes sordos pueden expresar ideas, pero aún dependen de intérpretes o materiales adicionales para acceder a la información oral o escrita emitida por docentes y compañeros oyentes.

Por último, una mejora clave para futuras versiones de la aplicación es su integración con sistemas de gestión del aprendizaje (LMS), lo que permitiría su uso en plataformas educativas digitales. Esto brindaría mayores oportunidades de aprendizaje a distancia para estudiantes sordos y facilitaría su acceso a contenidos educativos en línea adaptados a sus necesidades.

Conclusiones

El desarrollo de una aplicación móvil basada en inteligencia artificial para la traducción de la Lengua de Señas Mexicana (LSM) al español representa un avance significativo en la educación inclusiva. Esta herramienta proporciona una solución accesible para facilitar la comunicación de estudiantes sordos con sus docentes y compañeros, contribuyendo parcialmente a reducir las barreras lingüísticas en entornos educativos. Es importante señalar que la aplicación traduce la LSM al español, pero no de manera inversa,

por lo que no sustituye la labor de un intérprete ni elimina completamente las dificultades de comunicación, conocidas como barreras comunicativas.

Los resultados obtenidos evidencian la efectividad del modelo de *Deep Learning* implementado, el cual alcanzó una precisión superior al 90% en la detección de señas fijas y dinámicas, lo que demuestra el potencial del aprendizaje profundo para la traducción automática de la LSM en tiempo real.

La viabilidad de la aplicación en dispositivos móviles facilita su implementación en entornos educativos sin necesidad de hardware especializado, lo que amplía su accesibilidad a comunidades con recursos tecnológicos limitados. Además, su integración con metodologías de enseñanza inclusiva puede fortalecer el aprendizaje y la autonomía de los estudiantes sordos.

A pesar de estos avances, se identificó la necesidad de optimizar el modelo para mejorar el reconocimiento de frases completas y expresiones más complejas de la LSM, así como su desempeño en condiciones de baja iluminación o al detectar movimientos rápidos. Como líneas futuras de investigación, se propone la ampliación del conjunto de datos incorporando una mayor variabilidad de señas y facilitar la integración del sistema con plataformas educativas digitales (LMS) para maximizar su impacto en el aprendizaje inclusivo.

Líneas de trabajo futuras

Los resultados obtenidos en este estudio permitieron identificar áreas de oportunidad que exceden los objetivos originalmente planteados, pero que son de gran interés para investigaciones complementarias. A continuación, se presentan algunas líneas de trabajo futuras que podrían fortalecer el desarrollo de tecnologías de traducción de la Lengua de Señas Mexicana (LSM), así como su incorporación en la práctica docente y su integración curricular en entornos educativos reales.

1. Integración con sistemas educativos: Para maximizar el impacto de la aplicación, se recomienda su incorporación en plataformas de gestión del aprendizaje (LMS) utilizadas en escuelas y universidades. Esto permitiría que estudiantes sordos tengan acceso a materiales didácticos traducidos en tiempo real, facilitando su participación en clases y evaluaciones.
2. Colaboración con especialistas en educación inclusiva: La optimización de la aplicación debe realizarse en conjunto con docentes y expertos en la educación de

personas sordas. Su retroalimentación permitirá mejorar la interfaz, seleccionar señas más representativas y desarrollar funcionalidades adicionales que respondan a las necesidades pedagógicas específicas de este grupo de estudiantes.

3. Estudios futuros sobre el impacto en la adquisición del lenguaje: Se recomienda realizar investigaciones longitudinales para evaluar cómo el uso de esta aplicación influye en el aprendizaje de la LSM y en la adquisición del español como segunda lengua para personas sordas. Estos estudios pueden aportar evidencia valiosa sobre la efectividad de la herramienta y orientar mejoras en su implementación educativa.
4. Ampliación del conjunto de datos y mejoras en el modelo: Para incrementar la precisión y robustez del sistema, se sugiere ampliar la base de datos utilizada en el entrenamiento del modelo, incorporando variaciones en iluminación, posiciones de las manos y entornos de uso. Asimismo, la implementación de técnicas avanzadas de procesamiento del lenguaje natural (PLN) podría mejorar la traducción contextual de las señas en frases completas.
5. Desarrollo de versiones multi-plataforma: La aplicación podría expandirse a otros sistemas operativos, como iOS, y adaptarse para su uso en dispositivos de escritorio. Esto permitiría su adopción en una mayor variedad de entornos educativos y su integración con herramientas de videoconferencia para la educación a distancia.
6. Evaluación del desempeño en entornos reales: Resulta necesario llevar a cabo pruebas piloto en instituciones educativas para evaluar la efectividad de la aplicación en escenarios de uso real. Esto permitiría recopilar información sobre su impacto en la interacción entre estudiantes sordos y oyentes, así como identificar áreas de mejora para futuras actualizaciones.

Para finalizar, el presente estudio demuestra que la inteligencia artificial aplicada a la educación inclusiva puede mejorar significativamente la accesibilidad para estudiantes sordos. La implementación de esta tecnología en el aula representa un paso adelante hacia la equidad educativa, promoviendo un aprendizaje más autónomo y participativo para la comunidad sorda.

Referencias

- Amezcuca Aguilar, T., & Amezcuca Aguilar, P. (2018). Contextos inclusivos: el reconocimiento de la lengua de signos como derecho de las personas con diversidad funcional. *Index.comunicación*, 8(2), 123-148. ISSN-e 2174-1859.
- Amrutha, K., & Prabu, P. (2021). ML Based Sign Language Recognition System. *International Conference on Innovative Trends in Information Technology (ICITIIT)*. 1-6. Kottayam, India. <https://doi.org/10.1109/ICITIIT51526.2021.9399594>.
- Aquino Castro, R. A. (2018). *Reconocimiento e interpretación del alfabeto dactilológico de la lengua de señas mediante tecnología móvil y redes neuronales artificiales* (Tesis de licenciatura). Universidad Mayor De San Andrés, Facultad De Ciencias Puras Y Naturales, Carrera De Informática, La Paz, Bolivia.
- Berrones Yaulema, L. P., & Salgado Oviedo, S. A. (2023). La aplicación de la inteligencia artificial para mejorar la enseñanza y el aprendizaje en el ámbito educativo. *Esprint Investigación*, 2(1), 52–60. <https://doi.org/10.61347/ei.v2i1.52>
- Cruz Aldrete, M. (2008). *Gramática de la Lengua de Señas Mexicana* (Tesis de doctorado). Colegio de México.
- Cruz-Aldrete, Miroslava, & Sanabria Ramos, Edgar. (2024). «Enséñame un cuento»: una aproximación al proceso de leer, traducir e interpretar en lengua de señas mexicana. *Káñina*, 48(2), 50-80. <https://doi.org/10.15517/rk.v48i2.60346>
- Díaz, J., Pulley, J., & Navarrete, P. (2025). Herramientas de Inteligencia Artificial en el Apoyo Educativo para Estudiantes con Necesidades Educativas Especiales (NEE) en Diferentes Discapacidades. *Revista Universidad De Guayaquil*, 139(1), 10-30. <https://doi.org/10.53591/rug.v139i1.1605>
- Espejel Cabrera, J. (2021). *Desarrollo de algoritmos para Traductor automático de lenguaje de señas Mexicanas (LSM)* (Tesis de maestría). Universidad Autónoma del Estado de México, Texcoco, Estado de México, México.
- Gallego Peralta, D. (2021). *Intérprete del lenguaje de signos en tiempo real mediante Machine Learning* (Tesis de licenciatura). Universidad de Málaga, Escuela Técnica Superior De Ingeniería Informática, Málaga, España.
- Gobierno de México [GoMex]. (2016). *El modelo educativo 2016: El planteamiento pedagógico de la reforma educativa*. Secretaría de Educación Pública (SEP).
- González-Rodríguez, J.-R., Córdova-Esparza, D.-M., Terven, J., & Romero-González, J.-A. (2024). Towards a Bidirectional Mexican Sign Language–Spanish Translation

- System: A Deep Learning Approach. *Technologies*, 12, 7.
<https://doi.org/10.3390/technologies12010007>
- Halder, A., & Tayade, A. (2021). Real-time Vernacular Sign Language Recognition using MediaPipe and Machine Learning. *International Journal of Research Publication and Reviews*, 2(5), 9-17.
- Heaton, J., Goodfellow, I., Bengio, Y., & Courville, A. (2018). Deep learning. *Genetic Programming and Evolvable Machines*, 19, 305–307.
<https://doi.org/10.1007/s10710-017-9314-z>
- Hurtado-Sánchez, C., Cárdenas-Valdez, J. R., & Calvillo-Téllez, A. (2024). Desarrollo de aplicación de realidad aumentada móvil para el aprendizaje de Lengua de Señas Mexicana. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 12(Especial4), 55-62. <https://doi.org/10.29057/icbi.v12iEspecial4.13331>
- Maciel Cataño, E. J., Estrada Gutiérrez, J. C., Flores Jiménez, A. B., Cano Lara, M., & Jiménez Rodríguez, M. (2024). Detección del abecedario de Lengua de Señas Mexicanas (LSM) usando MediaPipe, SVM y Random Forest. *Transregiones*, 7, 73–84. <https://revistatransregiones.com/web/index.php/tr/article/view/87>
- Makris, S. (2021). Virtual Reality for Programming Cooperating Robots Based on Human Motion Mimicking. *Cooperating Robots for Flexible Manufacturing*. Springer Series in Advanced Manufacturing. https://doi.org/10.1007/978-3-030-51591-1_18
- Martín Gómez, S. (2020). Aplicación de las Metodologías Ágiles al proceso de enseñanza-aprendizaje universitario. *Revista d’Innovació Docent Universitària*, 12, 62-73.
<http://dx.doi.org/10.1344/RIDU2020.12.7>
- Martínez, M., Rojano, J. R., Bárcenas, I. E., & Juárez, F. (2016). Identificación de lengua de señas mediante técnicas de procesamiento de imágenes. *Research in Computing Science*, 128, 121-129. <https://doi.org/10.13053/rcs-128-1-11>
- MediaPipe. (2024). *Guía de soluciones de MediaPipe*.
<https://ai.google.dev/edge/mediapipe/solutions/guide?hl=es-419>
- Mejía-Pérez, G. A., González, N., Alvarado, S., & López-Mendoza, A. (2022). *Glosario Universitario de Lengua de Señas Mexicana*. Universidad de Guadalajara.
<https://hdl.handle.net/20.500.12104/90742>
- Munguía Zatarain, I. (2017). Reseña de *Manos a la obra: lengua de señas, comunidad sorda y educación*, de Miroslava Cruz-Aldrete. *Iztapalapa. Revista de Ciencias Sociales y*

Humanidades, 83, 229-235.

<http://revistaiztapalapa.izt.uam.mx/index.php/izt/issue/archive>

- Pérez-Castro, J., & Cruz-Cruz, J. C. (2021). Inclusion-Exclusion Experiences of a Group of Deaf People Users of the Mexican Sign Language. *Revista Latinoamericana de Educación Inclusiva*, 15(1), 39-54. <https://doi.org/10.4067/S0718-73782021000100039>
- Rivas Perea, P. E. (2019). *Desarrollo de un intérprete básico del lenguaje de señas para dactilología empleando inteligencia artificial* (Tesis de maestría). Instituto Tecnológico de Nogales, México.
- Salgado Martínez, Gabriel Alejandro. (2024). *Aplicación móvil para la traducción de señas de la lengua de señas mexicana al español, utilizando Deep learning* (Tesis de licenciatura). Maestría en Ingeniería para la Innovación y Desarrollo Tecnológico, Universidad Autónoma de Guerrero, Guerrero, México.
- Salgado Martínez, G. A., Cuevas Valencia, R. E., Morales, A. F., & Catalán Villegas, A. (2024). Reconocimiento de la Lengua de Señas Mexicana Usando Deep Learning Mediante una Aplicación Móvil. *Ciencia Latina Revista Científica Multidisciplinar*, 8(5), 10697-10728. https://doi.org/10.37811/cl_rcm.v8i5.14458
- Salgado Martínez, G. A., Cuevas Valencia, R. E., Feliciano Morales, A., & Catalán Villegas, A. (2024). Reconocimiento de señas de la Lengua de Señas Mexicana mediante técnicas de Machine Learning. *XIKUA Boletín Científico De La Escuela Superior De Tlahuelilpan*, 12(Especial), 33-39. <https://doi.org/10.29057/xikua.v12iEspecial.12696>
- Screpnik, C. R. (2024). Tecnologías digitales en la educación inclusiva: oportunidades, desafíos y perspectivas para personas con discapacidad cognitiva. *UTE Teaching & Technology (Universitas Tarraconensis)*, 2, e3664. <https://doi.org/10.17345/ute.2024.3664>
- Tang, D. (2019). *Empowering novices to understand and use machine learning with personalized image classification models, intuitive analysis tools, and MIT App Inventor* (Tesis de maestría). Massachusetts Institute of Technology.
- Trujillo-Romero, F., & García Bautista, G. (2021). Reconocimiento de palabras de la Lengua de Señas Mexicana utilizando información RGB-D. *ReCIBE, Revista electrónica De*

Computación, Informática, Biomédica Y Electrónica, 10(2), C2–23.
<https://doi.org/10.32870/recibe.v10i2.209>

United Nations Educational, Scientific and Cultural Organization [UNESCO]. (2018).
Informe de seguimiento de la educación en el mundo de 2020: inclusión y educación.
https://unesdoc.unesco.org/ark:/48223/pf0000265329_spa

Vásquez Jiménez, J. C., Orduña Ramírez, M. E., Juárez González, C. A., Arellano Ambrosio,
S., & Oregán Silva, M. de J. (2024). Educa T Aplicación móvil para la enseñanza del
lenguaje mediante señas como herramienta de apoyo para el proceso de enseñanza
aprendizaje para niños con problemas auditivos en edad preescolar. *Ciencia Latina
Revista Científica Multidisciplinar*, 8(5), 6000-6016.
https://doi.org/10.37811/cl_rcm.v8i5.14017

Wadhawan, A., Kumar, P. (2020). Deep learning-based sign language recognition system for
static signs. *Neural Comput & Applic* 32, 7957–7968.
<https://doi.org/10.1007/s00521-019-04691-y>

Zafrulla, Z., Brashear, H., Starner, T., Hamilton, H., & Presti, P. (2011). American Sign
Language Recognition with the Kinect. *Proceedings of the 13th International
Conference on Multimodal Interfaces (ICMI '11)*, ACM.
<https://doi.org/10.1145/2070481.2070521>

Rol de Contribución	Autor (es)
Conceptualización	Rene Edmundo Cuevas Valencia «que apoya» Gabriel Alejandro Salgado Martínez
Metodología	Rene Edmundo Cuevas Valencia «que apoya» Gabriel Alejandro Salgado Martínez
Software	Rene Edmundo Cuevas Valencia «igual» Gabriel Alejandro Salgado Martínez
Validación	Rene Edmundo Cuevas Valencia «que apoya» Gabriel Alejandro Salgado Martínez.
Análisis Formal	Rene Edmundo Cuevas Valencia «igual» Gabriel Alejandro Salgado Martínez
Investigación	Rene Edmundo Cuevas Valencia «igual» Gabriel Alejandro Salgado Martínez
Recursos	Rene Edmundo Cuevas Valencia «igual» Gabriel Alejandro Salgado Martínez
Curación de datos	Rene Edmundo Cuevas Valencia «que apoya» Gabriel Alejandro Salgado Martínez
Escritura - Preparación del borrador original	Rene Edmundo Cuevas Valencia «que apoya» Gabriel Alejandro Salgado Martínez
Escritura - Revisión y edición	Rene Edmundo Cuevas Valencia «principal» Gabriel Alejandro Salgado Martínez
Visualización	Rene Edmundo Cuevas Valencia «principal» Gabriel Alejandro Salgado Martínez
Supervisión	Rene Edmundo Cuevas Valencia «principal» Gabriel Alejandro Salgado Martínez
Administración de Proyectos	Rene Edmundo Cuevas Valencia «igual» Gabriel Alejandro Salgado Martínez
Adquisición de fondos	Rene Edmundo Cuevas Valencia «igual» Gabriel Alejandro Salgado Martínez