

Inteligencia artificial y visión por computadora aplicada a la educación

Artificial intelligence and computer vision applied to education

Fecha de recepción: 2022-03-25 • Fecha de aceptación: 2022-05-06 • Fecha de publicación: 2022-06-10

Leonardo Antonio Sánchez López

Jalasoft, Ecuador

Leonardosanchez4h@hotmail.com

<https://orcid.org/0000-0002-1436-357X>

RESUMEN

El presente trabajo de investigación realiza una revisión bibliográfica sobre la inteligencia artificial, la visión por computadora, las herramientas de MediaPipe y aprendizaje automático, con el objetivo de generar una propuesta de tecnología que permita mejorar la calidad de las clases. A lo largo del trabajo se describe la situación actual que tienen los estudiantes respecto a las clases en modalidad virtual, se incluyen y explican tanto definiciones como el funcionamiento de los distintos temas, al igual que se incluyen aplicaciones de ellos en la vida cotidiana. De igual manera se incluye el aporte a la educación que brinda cada uno de los campos, y se realiza un análisis de trabajos similares. Finalmente, se realiza la propuesta de una herramienta tecnológica que puede mejorar la calidad de las clases en la modalidad virtual, siendo así, un aporte para la educación.

PALABRAS CLAVE: inteligencia artificial, visión por computadora, MediaPipe, educación, aprendizaje automático

ABSTRACT

This paper carries out a bibliographic review on artificial intelligence, computer vision, MediaPipe tools and machine learning, with the aim of generating a technology proposal to improve the quality of classes. Throughout the work the current situation of students with respect to virtual classes is described, both definitions and the functioning of the different topics are included and explained, as well as their applications in everyday life. Likewise, the contribution of each of the fields to education is included, and an analysis of similar works is made. Finally, a proposal is made for a technological tool that can improve the quality of classes in the virtual modality, thus being a contribution to education.

KEYWORDS: artificial intelligence, computer visión, MediaPipe, education, machine learning

Introducción

Durante la pandemia por covid-19, la cotidianidad cambió a una nueva modalidad virtual. Tanto el trabajo, como el estudio, y reuniones sociales, tuvieron que pasar a ser de modo digital; las reuniones virtuales aumentaron y fueron una pieza clave para continuar con ciertas rutinas. Sin embargo, el cambio de modalidad se dio de forma súbita, dejando sin cuidado muchas cuestiones importantes. En cuanto a la educación, se perdió el componente sensorial que brinda el aprendizaje en un aula y la atención personalizada y guía de un profesor. En vista de esta problemática, se apreció la necesidad de generar herramientas tecnológicas que puedan contribuir con soluciones. Es por ello que se revisaron las siguientes definiciones.

La Inteligencia Artificial (IA) y la Visión Computacional (VC) son dos campos interdisciplinarios que han tenido grandes avances y aplicaciones en un gran rango de industrias. El objetivo principal de la Visión Computacional es comprender el entorno de la manera más parecida posible a la percepción humana (Orhei, et al., 2021). Se busca diseñar software y hardware que interprete lo que le rodea o a lo que se expone de manera visual y gestione adecuadamente lo que ve. Por otro lado, la Inteligencia Artificial, en particular su vertiente del Aprendizaje Automático (AA) o Machine Learning, comprende un rango muy versátil de técnicas que intentan simular el pensamiento humano en programas y máquinas. Desde redes neuronales que pueden analizar imágenes o texto, hasta modelos predictivos, el Aprendizaje Automático se define por su habilidad para aprender los datos a los que es expuesto (Lovejoy et al., 2021). Está claro que existen similitudes y oportunidades de integración entre la VC y el AA. En especial, se puede usar el aprendizaje automático para desarrollar mejores algoritmos de visión computacional, adaptarlos a los requerimientos necesarios y de este modo aplicarlos en la educación.

Metodología

En primera instancia se describe algo de contexto sobre la educación virtual; de manera más específica se puede hablar de la educación básica elemental; es decir, segundo, tercero y cuarto año de básica; en esta etapa, los niños y niñas aprenden de temas elementales de suma importancia como son: operaciones básicas de matemáticas, escritura, lectura y temas relacionados a la motricidad fina y gruesa. Este proceso de aprendizaje se ve entorpecido con la nueva modalidad, debido a la falta de estímulos, a lo poco interactivo de las clases y a la falta de herramientas que permitan mejorar el aprendizaje, como bolígrafos digitales o pantallas táctiles con las que se pueda escribir o dibujar.

Es importante tener en cuenta lo tedioso del aprendizaje al solo tener que observar una pantalla, sin oportunidad de interactuar, más aún cuando se trata de niños de corta edad. Esto genera falencias en el aprendizaje y cabe recalcar que es un problema existente para la educación en todo nivel.

Es por ello que resulta necesario desarrollar tecnología que permita recuperar la interactividad del aprendizaje y este componente sensorial perdido; en vista de esta problemática, se realiza una



investigación documental en bases de datos académicas que permiten identificar el estado del arte referente al tema de estudio. En las siguientes subsecciones se describe lo encontrado.

2.1 Inteligencia artificial (IA)

Existen muchas definiciones para la IA, algunos investigadores prefieren el término inteligencia aumentada a inteligencia artificial, debido a que esta mantiene el cerebro humano como fuente de inteligencia, y sitúa al ordenador y sus programas como una herramienta con la que los humanos pueden mejorar o aumentar sus capacidades intelectuales. En otras palabras, los ordenadores se emplean para hacer lo que a los humanos les resulta más difícil (Holmes et al., 2019). Por otro lado, John McCarthy (2014) la define como la ciencia e ingeniería de crear máquinas inteligentes, especialmente programas inteligentes. Está relacionada con la tarea similar de utilizar ordenadores para comprender la inteligencia humana, pero la IA no tiene por qué limitarse a métodos biológicamente observables.

Es importante resaltar que la idea de inteligencia es también un concepto abstracto y al crear programas inteligentes en los ordenadores, se debe decidir si el programa pensará

y actuará como un humano o lo hará de forma racional y de igual manera, diseñar los comandos para que el programa lo haga. Entre las aplicaciones de la IA se tiene el análisis de grandes cantidades de datos, búsqueda de patrones, optimización de procesos, resolución de problemas, por mencionar algunos.

La IA y el aprendizaje automático se han investigado recientemente para su uso en dispositivos móviles, con el objetivo de mejorar la calidad de la computación y abrir nuevas aplicaciones. Sin embargo, el aprendizaje automático necesita una enorme potencia de cálculo para llevar a cabo un entrenamiento y un aprendizaje complicados (Chen et al., 2020).

2.1.1 Tipos de IA

IA débil, también llamada IA estrecha, ANI por sus siglas en inglés, es una IA entrenada y enfocada a realizar tareas específicas. La ANI es el motor de la mayoría de la IA que está rodeando el mundo hoy en día, pues la utilizan algunas aplicaciones muy robustas, como Siri de Apple, Alexa de Amazon, IBM Watson y los vehículos autónomos (IBM, 2020).

IA fuerte, se compone de la Inteligencia General Artificial (AGI) y la Superinteligencia Artificial (ASI). Este tipo de inteligencia es una forma teórica de IA en la que se habla de una máquina con inteligencia igual a la de los humanos; con conciencia autoconsciente y la capacidad de resolver problemas, aprender y planificar el futuro (IBM, 2020).

Actualmente la IA es un campo bastante estudiado, pues las posibilidades son amplias; con el poder de análisis de la computadora se pueden crear herramientas tecnológicas que mejoren la calidad de vida de las personas, así como también optimizar procesos y metodologías.

2.1.2. IA en la educación

El área de Aprendizaje Asistido por Ordenador (CAL) desarrolla alternativas para ayudar a los procesos de aprendizaje de los alumnos mediante el uso de tecnología digital y de IA. La IA puede ayudar a visualizar la trayectoria de aprendizaje de cada estudiante, así como sus puntos fuertes y débiles, las materias con mejor desempeño y las preferencias en cuanto a actividades de aprendizaje. Esto quiere decir que la IA puede personalizar el aprendizaje, ayudar a mejorar el desempeño y brindar opciones a los estudiantes.

Este trabajo debe realizarse con el apoyo de profesores, padres e instituciones educativas, mientras el alumno necesite de una guía al utilizar los algoritmos para ayudar a navegar por diversas rutas curriculares. De igual manera representa una herramienta potente para aquellos padres que buscan asistir el aprendizaje de sus hijos o quienes deciden realizar un aprendizaje autodidacta; tenemos el ejemplo de Duolingo o Elevate, ambas aplicaciones para celular.

Por otro lado, al tener en cuenta la enorme cantidad de tiempo que se dedica a calificar de forma manual los exámenes y los deberes, se pueden crear herramientas de IA que aprendan cómo califica un profesor y así optimizar y disminuir el tiempo que el profesor dedica. La IA no solo se utiliza para calificar exámenes de opción múltiple, sino también para evaluar ensayos (Pedró et al., 2019).

2.2 Visión por computadora (VC)

La visión por computadora (VC) es una rama de la inteligencia artificial (IA) cuyo objetivo es permitir que la computadora entienda el mundo por medio del procesamiento de señales digitales (Wang et al., 2013). Si la IA permite que las computadoras “piensen”, la VC les permite ver, observar y comprender.

La visión humana es similar a la VC, con la excepción de que las personas tienen una ventaja inicial, la visión humana distingue objetos, qué tan lejos están, si se están moviendo y si algo es incorrecto con una imagen de forma relativamente sencilla gracias al gran poder de procesamiento del cerebro, algo que es limitado con las computadoras. La VC se emplea en una variedad de industrias, incluidas la energética y los servicios públicos, la fabricación y la automatización, la medicina, ciencias computacionales y desde luego, la educación.

2.2.1 ¿Cómo funciona la VC?

Se requiere una gran cantidad de datos y se repite su análisis hasta detectar distinciones y, eventualmente, reconocer imágenes. Los datos, que en este caso son imágenes, pueden analizarse de diversas maneras, pues siguen siendo información. Sin embargo, se debe tener en cuenta que la computadora no puede observar las imágenes como un humano lo haría. Particularmente se utilizan dos tipos de herramienta para la VC.

Aprendizaje profundo: esta técnica emplea modelos algorítmicos para enseñar a una computadora sobre el contexto de los datos visuales. Si se suministran suficientes datos al modelo, la computadora “mirará” los datos y aprenderá a distinguir entre las imágenes. Los algoritmos hacen posible hacer cosas como esta (IBM, 2022).

Red neuronal convolucional (CNN): ayuda al “aspecto” de un modelo de aprendizaje automático o aprendizaje profundo dividiendo las imágenes en píxeles y asignando etiquetas a cada píxel. Crea predicciones sobre lo que está “viendo”, usando las etiquetas para hacer convoluciones en varias iteraciones y evalúa la precisión de sus predicciones hasta que las predicciones comienzan a hacerse realidad. Luego, reconoce imágenes de una manera similar a la humana (IBM, 2022).

2.2.2 La VC y la educación

La visión por ordenador en la educación puede ayudar a los estudiantes a alcanzar sus objetivos académicos, proporcionando una experiencia de aprendizaje personalizada basada en sus puntos fuertes y sus deficiencias. Cuando se compara con la enseñanza regular en el aula, también puede ayudar con la evaluación y la no obstrucción. La disponibilidad de cámaras de bajo coste y su uso generalizado en dispositivos electrónicos como teléfonos móviles y ordenadores permite a los educadores medir los niveles de compromiso de los alumnos mediante la visión por ordenador, dado que la tecnología puede interpretar las imágenes digitales capturadas y reaccionar adecuadamente con la IA y el aprendizaje profundo.

Ya que es imposible observar constantemente la conducta de un estudiante, los sistemas de visión por computadora brindan varios beneficios al sector de la educación, especialmente si la modalidad de aprendizaje es virtual. Durante la pandemia por covid, la educación a nivel mundial cambió de modalidad de forma abrupta; de parte de los docentes es imposible prestarle atención a cada una de las cámaras de sus alumnos durante las clases, en el caso de que estén encendidas.

Si bien la visión por computadora permite a los educadores monitorear el comportamiento de los usuarios mientras enseñan en línea, también ayuda a rastrear la participación de los estudiantes en las aulas tradicionales. Esto se puede usar para evaluar los niveles de interés y atención de los estudiantes, y luego los instructores pueden ajustar sus enfoques de enseñanza para captar más atención y optimizar la participación de los estudiantes. Finalmente, esta información puede utilizarse para mejorar las técnicas de enseñanza tradicionales y proporcionar a los estudiantes cursos y materiales personalizados en función de su capacidad de comprensión.

2.3 Aprendizaje Automático (*Machine Learning*)

El término *Machine Learning* (ML) se refiere a un tipo particular de inteligencia artificial que consiste en entrenar a computadoras para que estas “aprendan” (Romero, 2020). Más en específico, el aprendizaje automático consiste en un conjunto de modelos matemático-computacionales que buscan la relación entre distintas variables. Así pues, los problemas que pueden ser abordados por esta disciplina son aquellos que tienen una representación matemática con variables que pueden o no relacionarse entre sí.

Un modelo de ML “aprende” en cuanto se somete a datos e intenta hallar una relación entre estos datos de manera probabilística. En todo tipo de modelo existe un aspecto iterativo que les permite adaptarse a nuevos ambientes de forma independiente (Romero, 2020). Los modelos se clasifican de acuerdo con la cantidad y tipo de supervisión que tienen; estos son: Aprendizaje No Supervisado (*Unsupervised Learning*), Aprendizaje Supervisado (*Supervised Learning*), Aprendizaje Semi Supervisado (*Semi Supervised Learning*) y Aprendizaje de Reforzamiento (*Reinforcement Learning*).

2.3.1 Estrategia detrás de un modelo de aprendizaje automático

De acuerdo con Romero (2020) existen distintas etapas que conforman el proceso detrás de un modelo de ML. Estas etapas son: comprensión del problema, reunir los datos, preparación de datos, elección de modelo, entrenamiento del modelo y evaluación.

Comprensión del problema: determinar el problema que se quiere solucionar y resolver si se lo puede expresar en términos matemáticos.

Reunir los datos (*Data Collection*): se refiere a la colección de datos que se relacionen con el problema a tratar. Este paso puede requerir el uso de *hardware* especializado como sensores, trabajo de campo, o herramientas de *software* que permitan la colección de información. Es de suma importancia tomar buenas decisiones respecto a la colección de los datos porque tiene un gran impacto en el modelo. Los datos son guardados en bases de datos.

Preparación de datos (*Feature extraction and data cleaning*): normalmente los datos que se recolectan no están en un formato que pueda ser usado en los modelos de ML. Por ejemplo, según Chu et al. (2016), los datos pueden estar codificados en reportes complejos o documentos de libre formato. Para hacer los datos aptos para ser procesados, es esencial transformarlos a un formato que sea amigable con los algoritmos de minado de datos y modelos de aprendizaje automático. Estos formatos pueden ser: multidimensionales, series de tiempo, o semiestructurados. El formato multidimensional es el más usado, y consiste en uno donde tenemos distintos campos de datos que corresponden a distintas propiedades medibles que se refieren como características, atributos, variables, o dimensiones. Es crucial saber qué atributos son relevantes y cuáles no para el problema a tratar. En general, el proceso de extracción de atributos se hace a la par que la limpieza de los datos, donde datos erróneos o faltantes son estimados o corregidos.

Elección de modelo (*Analytical processing and algorithms*): En esta sección se deben elegir métodos analíticos efectivos que puedan trabajar con los datos procesados.

Entrenamiento del modelo (*Train the model*): Se aplica el modelo de forma iterativa sobre el test de entrenamiento.

Evaluación del modelo (*Evaluate the model*): Se prueba el modelo con el test de prueba.

Una de las aplicaciones del aprendizaje automático con mayores avances es el campo del reconocimiento de imágenes.

2.4 Reconocimiento de Imágenes mediante *Machine Learning*

De acuerdo con Martínez (2018) el reconocimiento de imágenes se ha visto desarrollado ampliamente mediante el uso de modelos de aprendizaje automático “debido a su gran utilidad social y a la mejora en tiempo y precisión que su desempeño ofrece compara con el de los humanos”. El reconocimiento de imágenes se refiere a los mecanismos que identifican de forma automática objetos dentro de imágenes proyectadas relacionados con formas, tamaños, colores, etcétera (Builes y Palacio, 2015).

Este proceso también tiene sus partes como cualquier proceso de ML, y son las de: adquisición de imágenes, pre-procesamiento, segmentación, extracción de rasgos y clasificación.

Hay diversos algoritmos usados para el reconocimiento de imágenes. Una de las familias más usadas es la familia HOG (Histogramas de Orientación del Gradiente). Estos algoritmos se basan en la división de la imagen en celdas de tamaño fijo, donde en cada una de ellas se realiza un cálculo de un histograma de sus orientaciones y se describe sus contenidos para obtener una descripción global de toda la imagen. El método consiste en la asignación de píxeles en intervalos de acuerdo a su gradiente (Martínez, 2018).

2.5 MediaPipe

Internamente desde 2012, *Google* lo ha estado utilizando en una variedad de productos y servicios, con la intención de analizar video y audio en tiempo real en *YouTube*. Se integró de manera gradual en muchos productos adicionales, incluido el sistema de percepción de *NestCam*, la identificación de objetos de *Google Lens* y *Gmail*, entre otros. *MediaPipe* es el cerebro detrás de algunos de los productos y servicios más innovadores que se usan a diario. A diferencia de otros marcos de aprendizaje automático que usan mucha potencia, *MediaPipe* utiliza muy poca. Es tan pequeño y eficiente que puede funcionar en dispositivos IoT integrados.

Con una denominación más técnica, se define a *MediaPipe* como una *framework*, para crear canalizaciones de aprendizaje automático para datos de series temporales, como video y audio. Está diseñado para los profesionales del aprendizaje automático (ML), incluyendo investigadores, estudiantes y desarrolladores de software, y su principal uso es el prototipado rápido de puntos de referencia en imágenes con modelos de inferencia y otros componentes reutilizables (Lugaresi et al., 2019). Este marco multiplataforma es compatible con escritorio/servidor, *Android*, *iOS* y dispositivos integrados como *Raspberry Pi* y *Jetson Nano*.

2.5.1 ¿MediaPipe funciona en tiempo real?

Las soluciones que ofrece *MediaPipe* no siempre funcionan en tiempo real, pues las soluciones se construyen sobre *MediaPipe Framework* que proporciona la API de calculadora (C++), la API de construcción de gráficos (*Protobuf*) y la API de ejecución de gráficos (C++, *Java*, *Obj-C*). Con las API, se pueden construir gráficos y escribir calculadoras personalizadas. El *Toolkit* es excelente, pero su rendimiento depende del *hardware* subyacente. Por ejemplo, si se hace una comparación

en dos computadores diferentes, es probable que en uno se vea un video HD (1280 × 720) y en el otro un video Ultra HD (3840 × 2160). Esto indica que la eficiencia de MediaPipe está directamente correlacionada con el *hardware* del equipo en el cual esté corriendo. Por eso se puede plantear de manera natural la siguiente pregunta: ¿cómo podría ayudar MediaPipe en la educación en tiempo de pandemia? y ¿cuáles son los requerimientos mínimos para su uso?

2.6 Reconocimiento de manos

El reconocimiento de gestos con la mano (HGR) es una forma natural e intuitiva de interacción persona-ordenador (HCI), que ha sido objeto de numerosos estudios; con una amplia gama de dispositivos de entrada y enfoques, el HGR basado en el esqueleto se convirtió en una opción popular debido a su resistencia a las fluctuaciones del fondo y la luz (Sung et al., 2021). Entre las herramientas utilizadas para el reconocimiento de gestos con la mano, *MediaPipe* dispone de una solución para ella; esta emplea el ML para inferir 21 puntos de referencia en 3D de una mano, a partir de un solo fotograma (MediaPipe, 2020), como se presenta en la *Figura 1*.

Figura 1

Puntos de referencia en la mano



Nota. MediaPipe (2020)

Resultados

Se ha encontrado que las diferentes herramientas tecnológicas pueden ser de mucho beneficio para la educación. El área de investigación tanto de la IA y la CV permite explorar una gran variedad de opciones para darle solución a las diversas problemáticas, resultado de la modalidad virtual en la educación. Resulta de especial interés el reconocimiento de gestos de la mano utilizando las herramientas de MediaPipe y se plantea el generar tecnologías de alto impacto para la educación. Por otro lado, es necesario tener en cuenta los requerimientos básicos para que el *software* de MediaPipe funcione en los distintos dispositivos que tienen a disposición tanto estudiantes como maestros. Asimismo, en temas de calidad de video, tamaño de la pantalla y conexión a internet.

3.1 Discusión: pizarra virtual

Con la herramienta de reconocimiento de gestos de la mano, se propone realizar un prototipo de pizarra virtual que pueda ser utilizada durante las clases en modalidad

virtual. Mientras se tenga la cámara activa, la pizarra debe detectar las manos de los estudiantes y mediante gestos con ellas permitirles dibujar sobre la imagen del video. De igual manera debe permitir borrar los trazos. La interfaz queda a decisión del desarrollador y los requerimientos de la institución o profesor que desee utilizar el programa. Finalmente se recomienda tener en consideración los dispositivos a los que profesores y alumnos tengan acceso en el momento de desarrollo.

Conclusiones

La educación se vio afectada por el cambio de modalidad abrupto, resultado de la pandemia por covid-19; se perdió mucho del componente sensorial que era clave para el aprendizaje de los niños y niñas de distintas edades, en especial de aquellos cursando el periodo importante de la educación elemental.

Se revisó información existente sobre la IA y la VC y se determinó que ambas son herramientas muy útiles para generar tecnología e innovar. MediaPipe es una herramienta de libre acceso, potente y compacta con la que se pueden desarrollar algoritmos y programas robustos pero compactos. Estas herramientas son usadas en la educación, la IA principalmente se ha usado en el ámbito administrativo y la VC en temas de monitoreo de comportamiento; sin embargo, al juntarlas se puede crear una herramienta más didáctica que mejore el aprendizaje en la modalidad virtual por lo que se propone desarrollar un modelo de pizarra virtual.

Es importante considerar el acceso que tengan padres, alumnos y profesores a los requerimientos tecnológicos básicos para poder utilizar las distintas herramientas tecnológicas. Esto debido a que por mejor que sea la tecnología creada, esta se vuelve obsoleta si no se puede utilizar o, a su vez, si no se puede utilizar de forma óptima.

Referencias

- Builes, A., y Palacio, E. (2015). *Aplicación del reconocimiento de imágenes para la manipulación robótica de objetos en movimiento* [Tesis de grado, Universidad Pontificia Bolivariana]. <https://repository.upb.edu.co/handle/20.500.11912/2452>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/access.2020.2988510>
- Chu, X., Ilyas, I., Krishnan, S., & Wang, J. (2016). Data cleaning: overview and emerging challenges. In Sigmod'16: *Proceedings of the 2016 international conference on management of data* (pp. 2201-2206). <https://doi.org/10.1145/2882903.2912574>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. The Center for Curriculum Redesign.
- IBM. (03 de junio de 2020). *What is Artificial Intelligence (AI)?* <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>
- IBM. (2022). *What is Computer Vision?* <https://www.ibm.com/topics/computer-vision#:~:text=Computer%20vision%20is%20a%20field,recommendations%20based%20on%20that%20information> .
- Lovejoy, C., Abbas, A., & Ratneswaran, D. (2021). An introduction to artificial intelligence in sleep medicine. *Journal Of Thoracic Disease*, 13(10), 6095-6098. doi:[10.21037/jtd-21-1569](https://doi.org/10.21037/jtd-21-1569)
- Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., Zhang, F., Chang, C., Yong, M., Lee, J., Chang, W., Hua, W., Georg, M. & Grundmann, M. (2019). MediaPipe: A Framework for Building Perception Pipelines. *arXiv preprint* <https://doi.org/10.48550/arXiv.1906.08172>
- Martínez, J. (2018). *Reconocimiento de imágenes mediante redes neuronales convolucionales* [Tesis de grado, Universidad Politécnica de Madrid]. <https://oa.upm.es/53050/>
- MediaPipe. (2020). *MediaPipe Hands*. <https://google.github.io/mediapipe/solutions/hands>
- McCarthy, J. (2017). What is AI? / Basic Questions. *Stanford University*. <http://jmc.stanford.edu/artificial-intelligence/what-is-ai/index.html>
- Orhei, C., Vert, S., Mocofan, M., & VasIU, R. (2021). End-To-End Computer Vision Framework: An Open-Source Platform for Research and Education. *Sensors*, 21(11), 3691. <https://doi.org/10.3390/s21113691>
- Pedró, F., Subosa, M., Rivas, A. y Valverde, P. (2019). *Artificial Intelligence in education: challenges and opportunities for sustainable development*. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000366994>

Romero, B. (2020). *Una introducción a los modelos de Machine Learning* [Tesis de grado, Benemérita Universidad Autónoma de Puebla] <https://hdl.handle.net/20.500.12371/10527>

Sung, G., Sokal, K., Uboweja, E., Bazarevsky, V., Baccash, J., Bazavan, E, Chang, C., & Grundmann, M. (2021). On-device Real-time Hand Gesture Recognition. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2111.00038>
Principio del formulario

Wang, C., Komodakis, N., & Paragios, N. (2013). Markov Random Field modeling, inference & learning in computer vision & image understanding: A survey. *Computer Vision and Image Understanding*, 117(11), 1610–1627. <http://dx.doi.org/10.1016/j.cviu.2013.07.004>

Copyright (2022) © Leonardo Antonio Sánchez López



Este texto está protegido bajo una licencia internacional [Creative Commons](#) 4.0.

Usted es libre para Compartir—copiar y redistribuir el material en cualquier medio o formato — y Adaptar el documento — remezclar, transformar y crear a partir del material—para cualquier propósito, incluso para fines comerciales, siempre que cumpla las condiciones de Atribución. Usted debe dar crédito a la obra original de manera adecuada, proporcionar un enlace a la licencia, e indicar si se han realizado cambios. Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que tiene el apoyo del licenciante o lo recibe por el uso que hace de la obra.

[Resumen de licencia](#) – [Texto completo de la licencia](#)

