

Robot humanoide Chris 5.5 en educación e investigación con visión artificial y reconocimiento facial

Abiud Ademir Bermúdez Aguilar
EsRobotica
EsRobotica
Usulután, El Salvador
es.robotica2019@gmail.com,
<https://orcid.org/0000-0003-2832-1204>

Resumen

En los últimos años se ha observado un crecimiento de los avances tecnológicos a nivel mundial principalmente en las ramas de robótica y la Inteligencia Artificial, dicho crecimiento ha ido a bordándose y adaptándose en conjunto con las diversas áreas de la ciencia. Estos progresos están transformando la forma en que vivimos, trabajamos y nos relacionamos, abriendo nuevas posibilidades y desafíos para la humanidad.

Esto es un precedente tanto social, educativo y laboral principalmente para los países subdesarrollados, de lo cual surge la premisa "Estamos preparando a las nuevas generaciones a las nuevas carreras y nuevos trabajos", a esta premisa surge la construcción, implementación y adaptación del robot humanoide llamado Chris en su versión actual 5.5, la cual se ha desarrollado con el fin de preparar a los estudiantes a las nuevas carreras y nuevos trabajos y a su vez en temas de inteligencia artificial, visión computacional en investigación y desarrollo.

El robot 5.5 ha sido desarrollado para realizar diferentes tipos de actividades tanto educativas como de servicio.

En el caso de la educación se plantea el uso del robot de una forma de aprendizaje gradual en los salones de clases, creando planes de estudio adecuados a la carga académica asignada por el ministerio de educación.

En el caso de servicio dependerá del área de trabajo un ejemplo de ello en la seguridad el robot cuenta con detección de rostro, colores, sonidos y otros sensores pueda reconocer e interpretar el entorno, así como hoteles, restaurantes, hogares entre otros, la investigación continua en desarrollo para realizar pruebas en las áreas mencionadas.

Palabras clave: social, educación, servicio, simulación, seguridad, aprendizaje

I. INTRODUCCIÓN

Poco a poco alrededor del mundo la robótica y la inteligencia artificial están tomando mayor auge en todas las áreas de las ciencias, la Federación Internacional de Robótica para el 7 de febrero de 2018: la automatización de la producción se aceleró en todo el mundo: 74 unidades de robot por cada 10.000 empleados fue el nuevo promedio de densidad global de robots en las industrias manufactureras

(2015: 66 unidades). Por regiones, la densidad promedio de robots en Europa es de 99 unidades, en las Américas 84 y en Asia 63 unidades.

Los 10 países más automatizados del mundo son: Corea del Sur, Singapur, Alemania, Japón, Suecia, Dinamarca, Estados Unidos, Italia, Bélgica y Taiwán. Esto es de acuerdo con las estadísticas mundiales de robots de 2017, emitidas por la Federación Internacional de Robótica (IFR) [1].

La IFR afirma que estamos en el comienzo de una revolución: la demanda de robots se ha acelerado considerablemente desde 2010, con un incremento del 15% anual, debido a los grandes avances tecnológicos y a la creciente tendencia a automatizar plantas industriales.

Se trata de un mercado que en ese momento superará los US\$150.000 millones, estimaciones de Bank of América Merrill Lynch.

Los países latinoamericanos más robotizados figuran muy por debajo en la lista, lejos del promedio global de 69 autómatas por cada 10.000 empleados.

México ocupa el puesto 30 con 33 robots por cada 10.000 trabajadores, Argentina el 36 con 16 unidades y Brasil el 38 con 11.

"Lo que muestran estas cifras es que, al contrario de lo que muchos creen, la penetración de los robots en la industria sigue siendo relativamente baja", le comenta a BBC Mundo Carsten Heer, de la IFR [1].

"A la vez, esos mismos números ponen de relieve el enorme potencial que tiene la robótica para seguir creciendo dentro de las economías".

Para Carsten Heer, de la Federación Internacional de Robótica, este efecto de cascada en toda la economía se explica con una fórmula sencilla.

"El uso de robots no sólo crea empleos calificados; también baja el costo de los productos, lo que a su vez despierta más interés de los consumidores y, como consecuencia, genera más ventas. Y más ventas siempre significan más puestos de trabajo", le asegura a BBC Mundo [2].

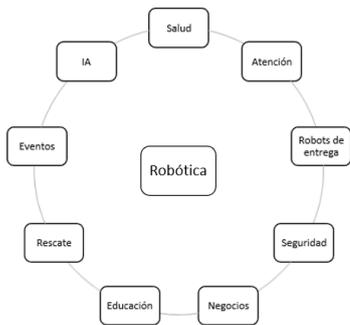
Con todo lo mencionado, conlleva a hacer una reflexión sobre Latinoamérica, y en este caso especial El Salvador, el cómo se está preparando a las nuevas generaciones tanto para los niños y como los jóvenes, para las nuevas carreras y los nuevos trabajos en temas afines a la robótica y la inteligencia artificial, por ello el autor con su experiencia en la construcción de robots educativos, sociales y de servicio tomo

a bien el crear un robot con fines en la educación, con el fin de motivar a las nuevas generaciones en la construcción, adaptación y programación de robots desde la parte educativa hasta el inicio del camino profesional con robots para la industria, el servicio y la investigación.

De esto surgió el robot humanoide Chris que fue pasando entre etapas y versiones hasta la versión 5.5, una versión funcional y lista para su etapa final, la cual es la impresión de todas sus piezas, la cual se llamara versión 6.0.

II. METODOLOGIA

Para el desarrollo de la construcción del robot se basa en los principios de una investigación aplicada [3], el inventor retoma la idea de sus versiones anteriores como robot Chris 5.0, el cual es un robot social y de servicio, de 1.30 cm con 200 funciones, programado en Visual Studio, Arduino y Android, con varios sensores como movimiento, luz, sonido, distancia, y su memoria de 32gb, el robot como tal tenía varias modalidades como seguridad, educación, salud, entretenimiento entre otros, el robot era controlado por medio del celular, sonidos y movimientos corporales, todo esto a través del aprender haciendo, y adaptando el robot a diferentes áreas de la ciencia y la educación como lo muestra fig.1.



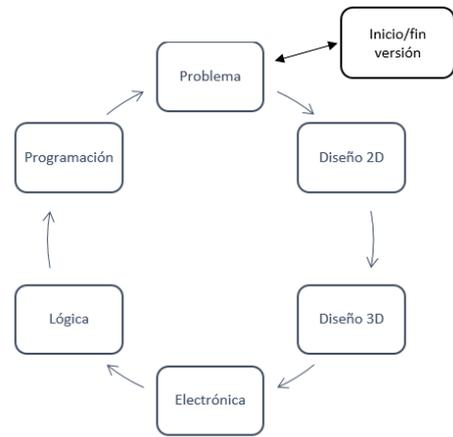
La fig.1 muestra las herramientas tecnológicas para las diferentes áreas de las ciencias enfocadas a las nuevas carreras y nuevos trabajos.

Cada versión del robot está pensando en superar a sus versiones anteriores y con una meta clara en la versión 6.0 la cual se basará en ser un robot 100% impreso en 3D, como lo muestra la fig.2.



Fig. 2. Muestra las versiones del robot Chris desde la versión 5.0 hasta la versión 5.5 y el diseño preliminar del robot 6.0.

Para la construcción de cada versión se basa en el siguiente esquema.



La fig.3. Muestra los pasos para la creación de un robot genérico, desde determinar el problema, hasta la programación, todo esto a través problemática de la investigación.

El primer paso para la construcción de un robot es el diseño, un bosquejo a mano (planos 2D), donde se hacen los primeros bocetos del robot, una vez claro el diseño del robot se pasa a planos en 3D con algún software de diseño, para posteriormente de ser necesario impresión 3D, una vez terminado se procese a la creación de lo que será la electrónica del robot, motores, servos, leds, sensores entre otros.

Posteriormente se hace un mejor análisis de los movimientos del robot, la programación del robot, su interfaz y formas de comunicación con él, así se hace una revisión general y de ser necesario se repetir el ciclo de la ilustración 3.

VERSIÓN 5.5 EN EDUCACION

La versión 5.5 es la actualización de la versión 5.3, como lo muestra la figura 2, tomando la base del robot y parte del cuerpo, se cambiaron los brazos, hombros, cabeza del robot por parte nuevas e impresas en impresión 3D, con esto iniciar la etapa de un robot que se tenga piezas en impresión 3D, para fines tanto educativos como comerciales.

La versión 5.5, es una etapa de cambio para tener un robot totalmente impreso en 3D, pero a su vez con manuales y guías para estudiantes y docentes, videos de uso, programación y guías con detalles para modificaciones, todo esto con el enfoque aprender haciendo, preparando a estudiantes a las nuevas carreras y nuevos trabajos, utilizando metodología STEAM.

Nuevas partes del robot y aplicaciones código abierto:

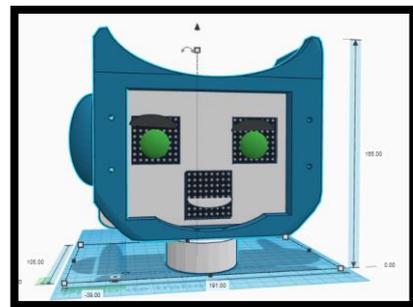


fig. 4. Rostro del robot.

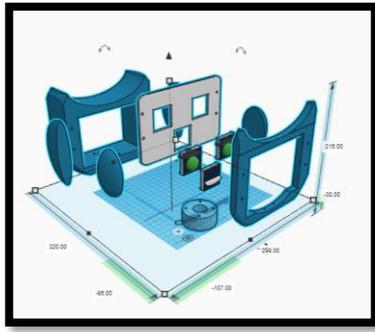


fig. 5. parte de las piezas de la cabeza del robot.



Fig. 6 Robot Chris 5.5 Armado

Herramienta de aprender haciendo:

El robot al ser adaptable a diferentes lenguajes de programación tanto comerciales como gratuitos que sean compatibles tanto a Python como Arduino, se crean manuales o guías de aprendizaje del funcionamiento del robot con ejemplos de actividades que podría realizar el robot desde atender a personas en un restaurante, una clínica, un almacén entre otros hasta actividades de seguridad de un local entre otros.

Al poseer su propio simulador de habla y su propio interfaz para simular estados de ánimo, puede establecer pláticas predeterminadas a través de sus funciones de habla, posee funciones básicas desde movimiento, desde desplazarse hasta saludar entre otros, para una comunicación a grandes distancias cuenta con su propio Bot para ser controlado desde cualquier parte del mundo por medio de Telegram privado, en el modo educativo, el robot funge para moldear y guiar tanto al docente y al estudiante con ejemplos prácticos desde movimientos hasta actividades básicas vistas para el hogar hasta una oficina.

En la figura 7 se observa un ejemplo con base a Arduino, en el cual los estudiantes junto al docente crean actividades para mover la cabeza y hacer acciones en valores determinados de sus movimientos.

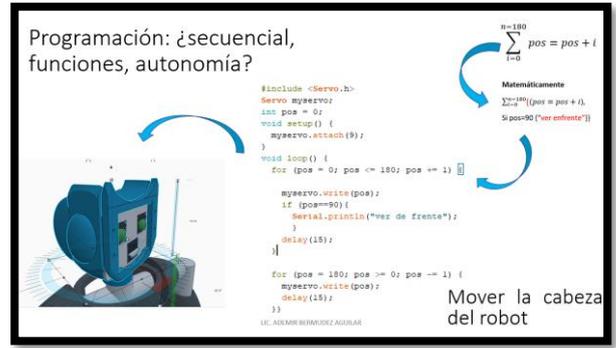


Fig. 7. se muestra un ejemplo de la Lógica y la programación, para mover la cabeza del robot visto desde matemática y programación con Arduino.

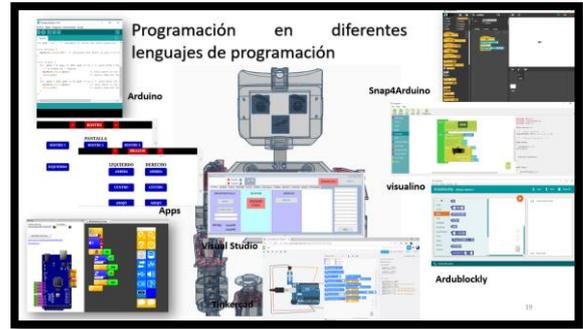


Fig. 8. Muestra algunos de los lenguajes de programación en el que se puede hacer rutinas con el robot.

El robot es adaptable a diferentes lenguajes de programación, desde programación básica para niños hasta robustos y avanzados como Arduino, Python y Visual Studio, algunos de ellos son de uso gratuitos y otros comerciales.

Se espera tener la versión impresa con sus manuales al finalizar el 2024, posteriormente realizar trabajo de campo con estudiantes y docentes de diferentes años académicos determinar la aceptación, uso, facilidad, motivación e imaginación de los estudiantes a las carreras afines a mecatrónica y adaptables a otras áreas de las ciencias para posteriormente pasar a la versión 100% impresa.

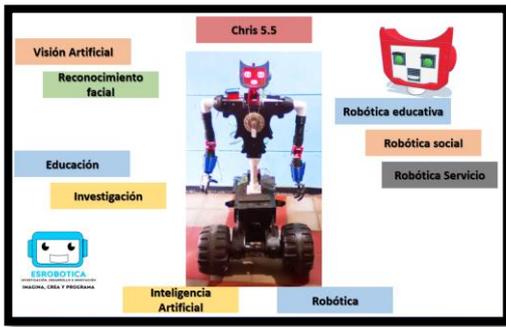
VERSIÓN 5.5 VISION ARTIFICIAL Y RECONOCIMIENTO FACIAL

La visión artificial es una disciplina de la inteligencia artificial la cual se centra en el procesamiento de imágenes para el reconocimiento de patrones, objetos, colores y formas con el uso de algoritmos en ambientes controlados con una cantidad de iteraciones en el procesamiento de imágenes [4].

A su vez la visión artificial en reconocimiento de formas permite identificar, contar, clasificar, determinar y agrupar todo esto dependiendo de su posición, orientación y tamaño, un objeto puede generar millones de imágenes diferentes en poco segundos, posteriormente analizarlas y clasificarlas, en lo que para un humano no es tan práctico de hacer, pues el reconocimiento debe tener en cuenta estas transformaciones geométricas, focalizándose en los invariantes [5].

Dentro de los campos con mayor proyección dentro de la Visión Artificial es el relacionado con el Reconocimiento

Biométrico Facial, el cual se centra en identificar y determinar lo que hace a una persona diferente a otra y esto a través de su rostro como ente principal [6].



la fig. 9. Muestra la segmentación del robot por bloques de trabajo.

La detección de objetos dentro de una imagen suele ser muy compleja y se debe previamente determinar que en si está buscando, es decir la computadora (robot) debe conocer que busca en un momento determinado (estático) y los posibles factores que pueden influir en el análisis de ese momento, desde luz, color, movimiento, entre otros, el asumir que todo está de forma estática para la detección de objetos presenta muchos retos, entre ellos:

- La modelación de objetos (determinar personas y fondos).
- Los cambios en el entorno (luz, movimientos).
- Los colores y variaciones en un tiempo determinado.

Dentro de una imagen o foto se deben considerar todas las posibles opciones (ventanas), de lo que se busca y clasificarlos en posibles candidatos y no candidatos [7].



Fig. 10: la ilustración de referencia de parte de la Universidad Autónoma de Barcelona [8].

En la figura 10 se observa los procesos de extracción de características de una imagen determinada.

Proceso para decisiones de candidatos:

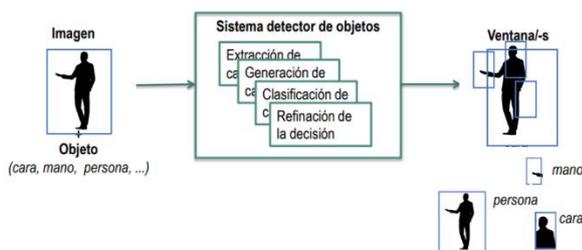


Fig. 11: Sistema detector de objetos [8].

La figura 11 muestra el sistema detector de un objeto específico o de varios objetos a la vez.

DETECCIÓN DE ROSTRO (OPEN CV):



Fig. 12. logo de OpenCV

OpenCV de la figura 12, es una biblioteca de Python que está diseñada para resolver problemas de visión por computadora. OpenCV fue desarrollado originalmente en 1999 por Intel, pero más tarde fue apoyado por Willow Garage. OpenCV soporta una amplia variedad de lenguajes de programación como C++, Python, Java, etc. Soporte para múltiples plataformas, incluyendo Windows, Linux y MacOS.

OpenCV Python no es más que una clase contenedora para la biblioteca original de C ++ que se utilizará con Python. Con esto, todas las estructuras de matrices OpenCV se convierten a/desde matrices NumPy. Esto hace que sea más fácil integrarlo con otras bibliotecas que usan NumPy. Por ejemplo, bibliotecas como SciPy y Matplotlib [9].

Para lograr el reconocimiento de un rostro en una imagen se realizan dos etapas o pasos de procesamiento con sus respectivas técnicas y algoritmos. En la primera etapa se utilizan clasificadores en cascada y el algoritmo de Viola-Jones para lograr detectar un rostro dentro de la imagen [10].

Viola-Jones utiliza clasificadores en cascada los cuales se entrenan utilizando el algoritmo de AdaBoost [11], con el cual se logra crear clasificadores fuertes a partir de clasificadores débiles.

En la segunda etapa se realiza el reconocimiento del rostro de una persona, comparando el rostro detectado en la imagen con una serie de imágenes guardadas llamadas imágenes de muestra. Para este reconocimiento, se utiliza el algoritmo de Eigenfaces [12], el cual realiza la comparación de las imágenes de muestra con la del rostro detectado, e indica si existe concordancia.

Dentro de una imagen (foto) se deben considerar todas las posibles ventajas, pero el determinar qué es lo que se busca y que no se conoce como candidatos y no candidatos [13].



Fig. 13: robot en pruebas de detección de rostro.

Para las primeras pruebas como muestra la figura 13 el robot tenía que cumplir los siguientes supuestos:

- 1- El robot debe estar detenido en ese momento, para analizar a la persona
- 2- La persona debe estar quieta para hacer analizado.
- 3- Controlar la intensidad de luz del lugar
- 4- Angulo efectivo: la cámara del robot este directo a el rostro de la persona al analizar.

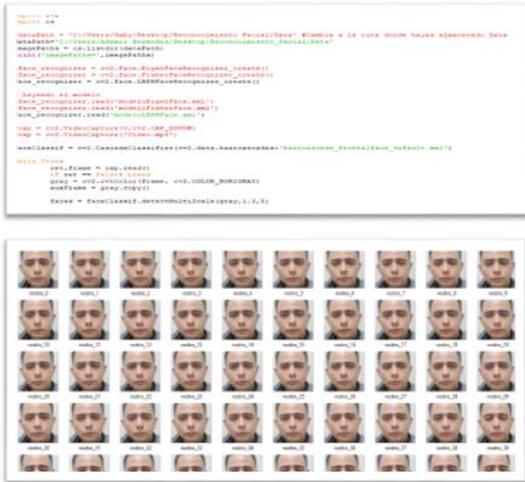


Fig. 14: robot tomando fotos para su entrenamiento.

La figura 14 muestra pruebas de toma de rostros de una persona en tiempo real.

¿Cómo una computadora interpreta una imagen?

Las computadoras (robots) por sí mismas no interpretan imágenes, no son capaces de determinar quién está en la imagen, lo que la computadora lee en cualquier imagen es un valor entre un rango entre 0 y 255.

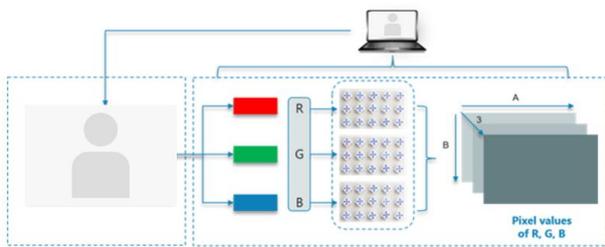


Fig. 15: interpretación de imágenes.

MACHINE LEARNING

El aprendizaje automático (ML), es un tipo de inteligencia artificial (IA) que proporciona a los ordenadores la capacidad de aprender sin ser explícitamente programados. El aprendizaje automático se centra en el desarrollo de programas informáticos que pueden cambiar cuando se exponen a nuevos datos.

El proceso de aprendizaje automático es similar al de la minería de datos. Ambos sistemas buscan a través de datos para encontrar patrones. Sin embargo, en lugar de extraer datos para la comprensión humana, como es el caso de las aplicaciones de minería de datos, el aprendizaje automático

utiliza esos datos para detectar patrones en los datos y ajustar las acciones del programa en consecuencia [14].

Los algoritmos de aprendizaje automático se clasifican a menudo como supervisados o no supervisados. Los algoritmos supervisados pueden aplicar lo que se ha aprendido en el pasado a los nuevos datos. El aprendizaje supervisado busca realizar predicciones a futuro basándose en características y comportamientos que se han detectado y clasificado en datos almacenados, datos históricos o conocimiento previo en el que nos podemos apoyar para hacer predicciones o tomar decisiones [15].

Los algoritmos no supervisados pueden extraer inferencias de conjuntos de datos. El aprendizaje no supervisado a diferencia del supervisado usa datos históricos que no estén etiquetados ni clasificados, con el fin de explorarlos y encontrar una estructura para relacionarlos y para organizarlos.

ALGORITMO DE BOOSTING

Los algoritmos de Boosting se refiere a un método general y probablemente el más eficaz para producir una Regla de predicción muy precisa, por la combinación de reglas débiles y moderadamente imprecisas [16].

El Boosting consiste en tomar una serie de clasificadores débiles y combinarlos para construir un clasificador fuerte con la precisión deseada. La idea se basa en que varios clasificadores sencillos, cada uno con una precisión 15 muy baja, se combinan para formar un clasificador de mayor precisión [17].

El Boosting tiene sus raíces en un marco teórico para el estudio del aprendizaje de máquina (Machine Learning), llamado "PAC" (Probably Approximately Correct) Learning Model, expuesto en 1984 por Leslie Valiant [18].

Convirtiéndose en el modelo más importante en la teoría del aprendizaje computacional. Kearns y Valiant fueron los primeros en plantear la cuestión de si un algoritmo de aprendizaje "débil" puede ser "Impulsado", utilizando PAC, en un algoritmo más preciso "fuerte" [19]. Los primeros experimentos con estos primeros Algoritmos de impulsos fueron llevados a cabo en una tarea OCR (Optical Character Recognition).

Entre los diferentes algoritmos de impulso (Boosting), tres de los más importantes son:

- AdaBoost (Adaptive Boosting)
- Gradient Tree Boosting
- XGBoost

CARACTERÍSTICAS HAAR

Las características Haar-Like, son las características utilizadas en la visión artificial para la detección de objetos en imágenes digitales. Estas características son utilizadas por el método de la Viola y Jones [20].

Una simple característica rectangular de tipo Haar puede definirse como la diferencia de la suma de píxeles de las áreas dentro del rectángulo, que puede estar en cualquier posición y escala dentro de la imagen original [21].

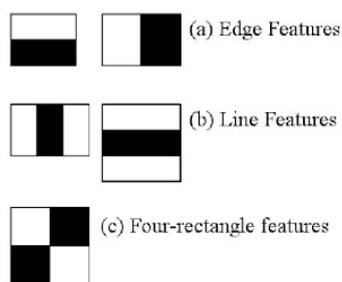


Fig. 16: Características de Tipo Haar [22]

La primera característica seleccionada se basa en la propiedad de que la región de los ojos es a menudo más oscura que la región de la nariz y las mejillas. La segunda característica seleccionada se basa en la propiedad de que los ojos son más oscuros que el puente de la nariz.

CLASIFICADOR DÉBIL(SENCILLO)

Viola y Jones utilizan un algoritmo que busca entre una gran cantidad y variedad de características Haar de la imagen, un clasificador débil o sencillo se encarga de buscar en la imagen características sencillas que correspondan con un posible rostro.

Se llama débil porque solo no puede clasificar la imagen, pero junto con otros clasificadores forma un clasificador fuerte.

CLASIFICADOR FUERTE

Un clasificador fuerte, está formado por varios clasificadores débiles. Este clasificador busca características de mayor complejidad en la imagen. El clasificador fuerte es una suma ponderada de estos clasificadores débiles.

ADABOOST (ADAPTIVE BOOSTING)

Adaboost propone entrenar iterativamente una serie de clasificadores base, de tal modo que cada nuevo clasificador preste mayor atención a los datos clasificados erróneamente por los clasificadores anteriores, y combinarlos de tal modo que se obtenga un clasificador con elevadas prestaciones [23].

CLASIFICADOR HAAR EN CASCADA

El Clasificador Haar en cascada, es un método desarrollado por Viola & Jones [10] y es una versión del algoritmo Adaboost [24]. Es un clasificador basado en árboles de decisión con entrenamiento supervisado, son utilizados para realizar el reconocimiento de un rostro en una imagen, utilizando clasificadores débiles para cada una de las características que se desea detectar.

En el análisis de una imagen en busca de un rostro, se debe recorrer la imagen completamente, esto se realiza tomando pequeñas ventanas de la imagen original. La mayor parte de las ventanas que se analizan corresponden con porciones de la imagen donde no se encuentran rostros, por lo tanto, un método rápido y sencillo, es analizar la pequeña ventana de la imagen, si no es un rostro, desecharla y no procesarla de nuevo.

De esta manera, se optimiza el tiempo necesario para comprobar una posible región de un rostro en la imagen completa. Para realizar el proceso mencionado anteriormente, Viola-Jones utiliza la Cascada de Clasificadores.

En lugar de aplicar todas las características, en una ventana, agrupa las características en diferentes etapas de los clasificadores y aplica una por una. (Normalmente las primeras etapas contendrán un número muy reducido de características a usar). Si una ventana falla en la primera etapa se desecha y no se evalúan las características restantes en la ventana. Si pasa, se aplica la segunda etapa de funciones y se continua el proceso. La ventana que pasa por todas las etapas es una región donde se encuentra un rostro.

IMPLEMENTACIÓN DEL MODELO DE DESARROLLO

Para el desarrollo de la aplicación para el reconocimiento de rostros se eligió el modelo Incremental. Esta elección se basó en el hecho de que los requerimientos de la aplicación son los suficientemente estables, ya que estos fueron definidos con anticipación y formaron parte de la investigación, y de esta forma poder realizar el desarrollo en iteraciones; al final de cada iteración se cuenta con una versión de la aplicación que cuenta con funcionalidad lista para ser probada.

El modelo Incremental permite tener de forma temprana un prototipo de la aplicación, en la cual se implemente la funcionalidad relacionada a la detección de rostros. Un segundo incremento con la funcionalidad relacionada con el entrenamiento y el reconocimiento de una persona. Un tercer incremento estará relacionado a la parte de usabilidad e interfaz de usuario.

Con este modelo es posible probar cada módulo de la aplicación, detectar las fallas corregirlas y seguir con el siguiente modulo, sin necesidad de esperar a tener toda la funcionalidad implementada para iniciar con las pruebas. Esto permite una retroalimentación temprana y la posibilidad de realizar ajustes específicos, sin tener que realizar cambios a todo el desarrollo realizado.

CONCLUSIONES.

Educación:

El robot se encuentra aún en etapa de mejoras en diseño, pero se ha logrado avanzar en electrónica y programación, se espera que pronto este en pruebas en colegios, escuelas, instituciones y universidades, para establecer si el robot este acto para dicho fin el cual es: Crear un Robot semi humanoide con fines educativos y aplicando metodología STEAM para preparación de los niños y jóvenes a las nuevas carreras y nuevos trabajos.

Reconocimiento de rostro:

En la actualidad aun el robot tiene limitaciones para detectar, analizar y comparar dos o más rostros, las librerías actuales, aun se trabaja en una estructura para reducir los errores, generando entrenamiento por entrenamiento con el robot, analizando diferentes rostros para poder diferencial entre una persona de otra y a su vez determinar quien es la persona reconocienda.

Una vez se pase esta etapa crearan actividades especificas para robot, ejemplo personas ingreando a un salon de clase y el robot mencionar a cada uno por su nombre de ingreso al salón..

REFERENCIAS

- [1] Heer, C. (s.f.). Federación Internacional de Robótica. Obtenido de <https://ifr.org/ifr-press-releases/news/robot-density-rises-globally>

- [2] Seitz, M. (17 de Marzo de 2017). BBC. Obtenido de <https://www.bbc.com/mundo/noticias-39267567>
- [3] Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la Investigación* (6 ed.). McGraw Hill.
- [4] Santa María Pinedo, J. C., Ríos López, C. A., Rodríguez Grández, C., & García Estrella, C. W. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*, 1(2), 15–26. <https://doi.org/10.51252/rcsi.v1i2.131>
- [5] Kamlofsky, J., & Bergamini, M. L. (2014). Herramientas de análisis de imágenes digitales para la visión artificial. <http://sedici.unlp.edu.ar/handle/10915/41252>
- [6] Caballero Barriga, E. R. (2017). [APLICACIÓN PRÁCTICA DE LA VISIÓN ARTIFICIAL PARA EL RECONOCIMIENTO DE ROSTROS EN UNA IMAGEN](https://www.udistrital.edu.co/) (udistrital.edu.co)
- [7] Santa María Pinedo, J. C., Ríos López, C. A., Rodríguez Grández, C., & García Estrella, C. W. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*, 1(2), 15–26. <https://doi.org/10.51252/rcsi.v1i2.131>
- [8] López, A., Vanrell, M., & Valveny, E. (2022). Detección de objetos | Coursera. <https://www.coursera.org/learn/deteccion-objetos>
- [9] Anirudh Rao. (2021). *Tutorial de OpenCV Python | Visión artificial con OpenCV | Edureka*. <https://www.edureka.co/blog/python-opencv-tutorial/>
- [10] Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1. <https://doi.org/10.1109/CVPR.2001.990517>
- [11] Mayhua-Lopez, E., Gomez-Verdejo, V., & Figueiras-Vidal, A. R. (2012). Real adaboost with gate controlled fusion. *IEEE Transactions on Neural Networks and Learning Systems*, 23(12), 2003–2009. <https://doi.org/10.1109/TNNLS.2012.2219318>
- [12] Turk M, Pentland A. Eigenfaces para el reconocimiento. *J Cogn Neurosci*. Invierno de 1991; 3(1):71-86. doi: 10.1162/jocn.1991.3.1.71. PMID: 23964806.
- [13] López, A., Vanrell, M., & Valveny, E. (2022). Detección de objetos | Coursera. <https://www.coursera.org/learn/deteccion-objetos>
- [14] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Vanderplas, J., Passos, A., Cournapeau, D., Gramfort, A., Thirion, B., Grisel, O., Dubourg, V., Passos, A., Brucher, M., & Duchesnay, A. (2011). Scikit-learn: Machine Learning in Python Gaël Varoquaux Bertrand Thirion Vincent Dubourg Alexandre Passos PEDREGOSA, VAROQUAUX, GRAMFORT ET AL. Matthieu Perrot. *Journal of Machine Learning Research*, 12, 2825–2830. <http://scikit-learn.sourceforge.net>.
- [15] Sebastiani, F. (2002). Machine Learning in Automated Text Categorization. *ACM Computing Surveys (CSUR)*, 1–47. www.ira.uka.de/bibliography/Ai/automated.text.
- [16] Kearns, M., & Valiant, L. (1994). Cryptographic Limitations on Learning Boolean Formulae and Finite Automata. *Journal of the Association for Computing Machinery*, 41(1), 67–95.
- [17] Gómez-Verdejo, V., Ortega-Moral, M., Arenas-García, J., & Figueiras-Vidal, A. R. (2006). Boosting by weighting critical and erroneous samples. *Neurocomputing*, 69(7–9), 679–685. <https://doi.org/10.1016/J.NEUCOM.2005.12.011>
- [18] Valiant, G. (1984). A Theory of the Learnable. 1134–1142. <https://dl.acm.org/doi/pdf/10.1145/1968.1972>
- [19] Kearns, M., & Valiant, L. (1994). Cryptographic Limitations on Learning Boolean Formulae and Finite Automata. *Journal of the Association for Computing Machinery*, 41(1), 67–95.
- [20] Viola, P., & Jones, M. J. (2004). Robust Real-Time Face Detection. *International Journal of Computer Vision* 2004 57:2, 57(2), 137–154. <https://doi.org/10.1023/B:VISI.0000013087.49260.FB>
- [21] Papageorgiou, C. P., Oren, M., & Poggio, T. (1998). General framework for object detection. *Proceedings of the IEEE International Conference on Computer Vision*, 555–562. <https://doi.org/10.1109/ICCV.1998.710772>
- [22] OpenCV: Clasificador en cascada. (n.d.). Retrieved December 14, 2022, from https://docs.opencv.org/3.4/db/d28/tutorial_cascade_classifier.html
- [23] Mayhua-Lopez, E., Gomez-Verdejo, V., & Figueiras-Vidal, A. R. (2012). Real adaboost with gate controlled fusion. *IEEE Transactions on Neural Networks and Learning Systems*, 23(12), 2003–2009. <https://doi.org/10.1109/TNNLS.2012.2219318>
- [24] Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55(1), 119–139. <https://doi.org/10.1006/JCSS.1997.1504>.