www.komputersapiens.org

KOMPUTER SAPIENS

Año 16
Volumen 1
Ene - Abr 2024

Revista de Divulgación de la Sociedad Mexicana de Inteligencia Artificial

DESCIFRANDO EMOCIONES USANDO **AUTO-MACHINE LEARNING**

EVALUACIÓN DE HABILIDADES EN **CIRUJANOS LAPAROSCÓPICOS**

IDENTIFICACIÓN DE **IDEACIÓN** SUICIDA EN **COMENTARIOS DE TEXTO EN ESPAÑOL**

DISPOSITIVO DE **NAVEGACIÓN PARA PERSONAS CIEGAS**

RECONOCIMIENTO DE BRÓCOLI EN **IMÁGENES RGB-D**

AJEDREZ COMPUTACIONAL: ¿CÓMO LA INTELIGENCIA ARTIFICIAL SE CONVIRTIÓ EN LA CAMPEONA DEL MUNDO?

GENERACIÓN DE DATOS SINTÉTICOS MEDIANTE **REDES GENERATIVAS ADVERSARIAS**

SEGURIDAD VIAL USANDO **TERMOGRAFÍA** Y VISIÓN ARTIFICIAL

ALGORITMOS GENÉTICOS EN PROYECTOS DE **CONSTRUCCIÓN**

ISSN 2007-0691

©Komputer Sapiens, Año XVI Volumen I, enero-abril 2024, es una publicación cuatrimestral de la Sociedad Mexicana de Inteligencia Artificial, A.C., con domicilio en Ezequiel Montes 56 s/n, Fracc. los Pilares, Metepec, Edo. de México, C.P. 52159, México, http://www.komputersapiens.org, correo electrónico: editorial@komputersapiens.org, tel. +52 (833)357.48.20 ext. 3024, fax +52 (833) 215.85.44. Impresa por Sistemas y Diseños de México S.A. de C.V., calle Aragón No. 190, colonia Álamos, delegación Benito Juárez, México D.F., C.P. 03400, México, se terminó de editar el 31 de diciembre de 2023.
Reserva de derechos al uso exclusivo número 04-2009-111110040200-102 otorgado por el Instituto Nacional de Derechos de Autor. ISSN 2007-0691.
Los artículos y columnas firmados son responsabilidad exclusiva de los autores y no reflejan necesariamente los puntos de vista de la Sociedad Mexicana de Inteligencia Artificial. La mención de empresas o productos específicos en las páginas de Komputer Sapiens no implica su respaldo por la Sociedad Mexicana de Inteligencia Artificial.
Queda estrictamente prohibida la reproducción total o parcial por cualquier medio, de la información aquí contenida sin autorización por escrito de los editores.
Komputer Sapiens es una revista de divulgación en idioma español de temas relacionados con la inteligencia artificial.
Creada en LaTeX, con la clase **papertex** disponible en el repositorio *CTAN*: Comprehensive TeX Archive Network, http://www.ctan.org/
Indizada en el IRMDCT de CONACYT y en Latindex.

Directorio SMIA

Presidente	Hiram Calvo Castro
Vicepresidenta	María de Lourdes Martínez Villaseñor
Secretario	Hiram Eredin Ponce Espinosa
Tesorera	Obdulia Pichardo Lagunas
Vocales:	Ildar Batyrshin
	Sabino Miranda Jiménez
	Roberto A. Vázquez Espinoza de los Monteros
	Oscar Herrera Alcántara
	David E. Pinto Avendaño
	Noé Alejandro Castro Sánchez
	Iris Iddaly Méndez Gurrola
	Omar Montaño Rivas
	Antonio Marín Hernández
	Nestor Velasco Bermeo
	Gustavo Arroyo Figueroa
	Sofía N. Galicia Haro
	Juan C. Martínez Miranda
	Leobardo Morales Tiburcio
	Iván Olvera Rodríguez
	Gilberto Ochoa Ruíz
	César J. Nuñez Prado
	Víctor Josué Ruiz Martínez
	Bella Citlali Martínez Seis

Komputer Sapiens

Director general	Hiram Calvo Castro
Editora en jefe	Karina Mariela Figueroa Mora
Editor científico	Héctor Gabriel Acosta Mesa
Editores asociados	Marco Antonio Aguirre Lam
	Laura Cruz Reyes
Editor invitado	Ansel Y. Rodríguez González
Coordinadora de producción	Viridiana Mena Gómez
e-Tlakuilo	Karina Figueroa
	Rosa María Valdovinos
Estado del IArte	Reyna Carolina Medina Ramírez
	Jorge Rafael Gutiérrez Pulido
Sakbe	Claudia G. Gómez Santillán
	Laura Cruz Reyes
	Laura Gómez Cruz
IA & Educación	María Yasmín Hernández Pérez
	María Lucía Barrón Estrada
	J. Julieta Noguez Monroy
Deskubriendo Konocimiento	Alejandro Guerra Hernández
	Gildardo Sánchez Ante
Corrección de estilo	Gilberto Rivera Zárate
	Marcela Quiroz Castellanos
	Sonia Lilia Mestizo Gutiérrez
	Guillermo de Jesús Hoyos Rivera
	Susana Aurora Velasco Montiel
	Héctor Joaquín Fraire Huacuja
	Leonardo Romero Muñoz
	Nelson Rangel Valdez
	Nicandro Cruz Ramírez
Portada	María Fernanda Hernández Arroyo

Directores Fundadores

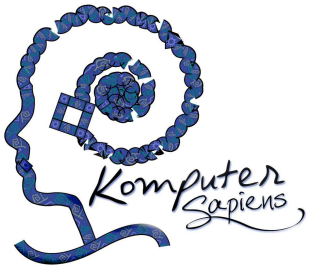
Carlos Alberto Reyes García
Ángel Kuri Morales

Comité Editorial

Ildar Batyrshin
Oscar Herrera Alcántara
Jesús Favela Vara
Sofía Natalia Galicia Haro
Miguel González Mendoza
Raúl Monroy Borja
Eduardo F. Morales Manzanares
Leonardo Garrido Luna
Carlos Alberto Reyes García
Antonio Sánchez Aguilar
Luis Enrique Sucar Succar
Ángel Kuri Morales
José A. Martínez Flores
Juan Manuel Ahuactzin Larios
Manuel Montes y Gómez
Ofelia Cervantes Villagómez
Alexander Gelbukh
Grigori Sidorov
Laura Cruz Reyes
Ramon Brena Pinero
Juan Humberto Sossa Azuela
Félix Castro

Árbitros

Héctor Acosta-Mesa
Federico Alonso-Pecina
Cleto Alvarez Aguilar
Miguel Alvarez-Carmona
Ángel Andrade
Fernando Arámbula
Ramon Aranda
Rocío Barrientos-Martínez
Carlos Barrios-Hernández
Edgard Benítez-Guerrero
Ramon Brena
Jose Camarena-Ibarrola
Luis A. Castro
Jaime Cerda
Angel Díaz-Pacheco
Luis Fernández-Martínez
Karina Figueroa Mora
Claudia Gómez
Karina Gutiérrez-Fragoso
Sergio Hernandez Mendez
Jose Alberto Hernandez-Aguilar
Paúl Hernandez-Herrera
Guillermo Hoyos-Rivera
Adriana Iñiguez Carrillo
Angel Kuri-Morales
Arturo Lopez Pineda
Julio Madera
Antonio Marin Hernandez
Aldo Márquez-Grajales
Jose Francisco Martínez Trinidad
Rolando Menchaca-Mendez
Sonia Mestizo-Gutiérrez
Carmen Mezura-Godoy
Raúl Monroy Borja
Fernando Montes
Eduardo Morales
Victor Morales
Daniela Alejandra Ochoa
Alberto Ochoa-Zezzatti
Karla Olmos-Sánchez
Angel Ortiz
Nancy Pérez-Castro
Humberto Pérez-Espinosa
Nora Reyes
Homero Vladimir Rios Figueroa
Rafael Rivera-Lopez
Ansel Y. Rodríguez González
Leonardo Romero
Angel Sánchez García
Jose Sánchez-Cervantes
Aurora Torres
Tania Turrubiates-Lopez
Gustavo Vargas Hakim
Carlos Alberto Fernández-y-Fernández



Contenido

Ajedrez computacional: ¿cómo la inteligencia artificial se convirtió en la campeona del mundo?
Pág. 6 ⇒María Fernanda Castro Sandoval y Edgar Alejandro Guerrero Arroyo

Descifrando emociones: clasificación de la soledad en diabéticos usando automachine learning
Pág. 12 ⇒ Luis Eduardo Maldonado-López, Alejandro Mateos-Moreno†, Isela Esther Juárez-Rojop, Carlos Alfonso Tovilla Zárate Y Eddy Sánchez-DelaCruz

Reconocimiento de brócoli mediante la anotación automática en imágenes RGB-D
Pág. 17 ⇒ Ricardo Ángel Álvarez Macedo, José Luis López Díaz, Héctor Alejandro Montes Venegas, Rosa María Valdovinos Rosas, José Raymundo Marcial Romero

Generación de Datos Sintéticos Mediante Redes Generativas Adversarias para Mejorar la Detección de Diabetes: Validación de Modelos Predictivos Basados en Aprendizaje Automático
Pág. 22 ⇒ Antonio García-Domínguez, Carlos E. Galván-Tejada y Rafael Magallanes-Quintanar

La Evaluación de Habilidades en Cirujanos Laparoscópicos: La Inteligencia Artificial al Rescate
Pág. 28 ⇒ Naidelyn Linares-Guzmán, Oscar-Eduardo Franco-Juan, Juan Hereiva-Osorio, Rigoberto Martínez-Mendez, Rosa-María Valdovinos-Rosas, Daniel Lorias-Espinoza

Detección de peatones con termografía y visión artificial aplicado en seguridad vial
Pág. 33 ⇒ Gerardo Bobadilla Valencia, Víctor Hugo Benítez Baltazar y Jesús Horacio Pacheco Ramírez

Propuesta de un algoritmo genético para establecer proformas en proyectos de construcción
Pág. 38 ⇒ José Manuel Pérez Esquivel, Cristina Juárez Landín y Marco Alberto Mendoza Pérez

La inteligencia artificial como apoyo en la identificación de ideación suicida en comentarios de texto en español
Pág. 43 ⇒ J. Patricia Sánchez-Solis, Diana Irasema Cervantes Arreola, Ana Brito Sosa, Gilberto Rivera, Rogelio Florencia

Dispositivo de navegación para personas ciegas basado en algoritmos de búsqueda
Pág. 47 ⇒ Yareni Cervantes Villalba, Marco Antonio Aguilar Cortés, Jacobo Robles Calderón, Guadalupe Robles Calderón

Columnas

Sapiens Piensa. Editorial pág. 2

e-Tlakuilo pág. 3

Estado del IArte pág. 4

Sakbe pág. 5

IA & Educación pág. 52

Deskubriendo Konocimiento pág. 54

Sapiens Piensa

Ansel Y. Rodríguez González

La influencia de la inteligencia artificial en una amplia gama de campos es un tema apasionante y en constante evolución. Esta tecnología se ha convertido en una pieza fundamental en ámbitos tan variados como el entretenimiento, el deporte, la salud, la seguridad, la construcción, la agricultura y el bienestar; y se ha convertido en una fuerza disruptiva y transformadora en la mayoría de los aspectos de nuestras vidas. En este número de tema libre se exploran las fronteras de la ciencia y la tecnología a través de una emocionante selección de artículos sobre inteligencia artificial.

Para activar nuestras neuronas el primer artículo se adentra en el fascinante mundo del ajedrez computacional, desvelando cómo la inteligencia artificial se ha convertido en una fuerza dominante en el juego de estrategia más antiguo del mundo. Los autores describen el modelo tradicional que utilizan árboles de juego y heurísticas, e introducen al lector en el modelo actual usado por *Leela Zero* y *Alpha Zero* que utilizan aprendizaje por refuerzo.

Los autores del segundo artículo examinan de cerca la intersección entre la tecnología y la salud, con un enfoque especial en el descifrado de emociones, donde se utiliza el auto-aprendizaje automático para clasificar la soledad en pacientes diabéticos.

Dentro de las páginas de este número, también se explora cómo la tecnología está transformando la agricultura. Un tercer artículo muestra la detección automática de cabezas de brócoli en imágenes RGB-D, lo cual podría ayudar a la extracción íntegra de la cabeza floral de esta hortaliza por parte de sistemas robóticos.

El siguiente artículo, nos sumerge en la aplicación de técnicas de inteligencia artificial en el diagnóstico y clasificación de enfermedades como la diabetes, pasando por la creación de datos sintéticos mediante Redes Generativas Adversarias para mejorar su detección.

Otra aplicación de la inteligencia artificial, también en el área de salud, es descrita en el quinto artículo de este número. Sus autores muestran una visión de cómo la inteligencia artificial puede usarse en la evaluación y formación de cirujanos laparoscópicos.

Por otro lado, la sexta entrega aventura al lector en el mundo de la seguridad vial y cómo puede realizarse la detección de peatones con termografía y visión artificial. La séptima entrega explora cómo la inteligencia artificial también puede ser una aliada en proyectos de construcción, con una propuesta de algoritmo genético para establecer presupuestos de costos de proyectos.

Casi al final de este número se retoma la aplicación de técnicas de inteligencia artificial en el área de salud, en particular salud mental. Los autores del octavo artículo muestran algoritmos de aprendizaje automático aplicados a identificar la ideación suicida en comentarios de texto en español.

Para finalizar este número, se seleccionó un artículo que describe una innovadora tecnología que podría cambiar la vida de las personas con discapacidad visual. Dicha innovación consiste en un dispositivo de navegación para personas ciegas basado en algoritmos de búsqueda.

Esperamos que el presente número sea una ventana a un mundo en constante evolución, donde la ciencia y la tecnología se entrelazan para llevarnos a nuevas alturas. Invitamos a los lectores a sumergirse en estos emocionantes artículos que destacan el poder de la innovación y la inteligencia artificial en el mundo actual.✷



Ansel Y. Rodríguez González. SNI Nivel I. Recibió los grados de Licenciado en Ciencias de la Computación y Maestro en Ciencias Matemáticas en la Universidad de la Habana, Cuba en 2004 y 2007 respectivamente. Recibió el grado de Doctor en Ciencias Computacionales en el INAOE en 2011. Actualmente tiene una cátedra CONACyT en la Unidad de Transferencia Tecnológica del CICESE. Sus intereses de investigación incluyen minería de datos, reconocimiento de patrones, aprendizaje por refuerzo y algoritmos evolutivos.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

e-Tlakuilo: Cartas de nuestros lectores

Karina Figueroa y Rosa María Valdovinos
etlakuilo@komputersapiens.org

En *Komputer Sapiens* nos hemos esforzado por estar "a sólo un click de distancia" a través de diferentes medios como Facebook, Twitter y correo electrónico. Les presentamos algunas de las preguntas que hemos recibido a través de estos medios.

La minería de datos como un camino para lograr un futuro sustentable.

Pregunta: Brandón Alexis Ballesteros.

¿Hasta qué punto la utilización de minería de datos no es una invasión a la privacidad? ¿Todos los datos obtenidos del minado se consiguen de manera legal o en algunos casos el usuario no tiene idea de lo que pasa en segundo plano?

La minería de datos como cualquier otra rama del quehacer científico necesita de datos para poder desarrollar nuevas técnicas y ampliar el conocimiento en dicha disciplina. Mediante el análisis de información perteneciente a diversos ámbitos, los científicos de datos encuentran limitaciones a las técnicas existentes, los cuales abren caminos inexplorados que inexorablemente conducen al desarrollo de avances como el aprendizaje profundo.

Una duda muy razonable es: ¿de donde surgen estos datos? Dependiendo del tipo de investigación, estos datos son obtenidos por expertos del campo en cuestión, con el consentimiento explícito de los involucrados. Un ejemplo clásico es el uso de registros médicos para la predicción de enfermedades como el cáncer o diabetes. En estos casos es indispensable la colaboración de médicos y pacientes en el entendimiento de que el propósito de los datos será única y exclusivamente para la investigación científica. En dichas circunstancias, la investigación debe de contar con la aprobación de los comités de ética de las instituciones participantes así como la correcta censura de información sensible (nombres, direcciones, etc.) de los pacientes. Por otra parte, pensando en la necesidad de desarrollar técnicas no invasivas en la medicina y otros ámbitos, se han desarrollado enfoques que permiten el desarrollo de algoritmos de aprendizaje sobre datos encriptados.

Este hecho es particularmente útil pues el desarrollo de modelos predictivos es posible sin que los involucrados puedan hurgar en la información. Para conocer más, recomendamos leer el estudio de Aldeen, Salleh y Razzaque de 2015.

Por otra parte, en el caso de investigaciones que involucran información perteneciente a las redes sociales o el internet, la única información que se utiliza es la que los mismos usuarios comparten libremente con el mundo. A pesar de la gran influencia del cine, el internet y la TV en la cultura popular, la realidad es que difícilmente pueden obtenerse los datos privados de los usuarios por medios ilegales. Esto no quiere decir que sea imposible el robo de información, sin embargo, lo más común es la venta de datos personales por parte de las compañías a terceros. Si bien, no podemos aportar pruebas de este hecho, el lector podrá dar fe de las veces en que los bancos, aseguradoras y demás compañías le acosan con incesantes llamadas a un número telefónico personal que difícilmente habrá compartido con familia y amigos.

En conclusión, la minería de datos es una herramienta más que beneficia a la población en campos que van desde la medicina hasta el entretenimiento. A pesar de ello, de forma similar a la energía nuclear que ilumina nuestras ciudades también es capaz de causar mucho daño, por lo cual depende de nosotros darle un uso correcto para el beneficio de la humanidad.

Referencia: Aldeen, Y. A. A. S., Salleh, M. y Razzaque, M. A. (2015). A comprehensive review on privacy preserving data mining. *SpringerPlus*, 4, 1-36.



© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Estado del IArte

Jorge Rafael Gutiérrez Pulido (@jrgpulido) y Reyna Carolina Medina Ramírez
estadoiarte@komputersapiens.org

Regular la IA

Parece que la inteligencia **natural** no es suficiente para resolver los problemas de convivencia que tenemos como humanidad. Desde el año pasado, el conflicto entre Rusia y Ucrania se ha convertido en una noticia más, no así para quienes lo están padeciendo. Recientemente otro conflicto milenario ha retomado protagonismo en las noticias, el Israelí-Palestino. En ambos conflictos, participan países que están inviertiendo en desarrollos de Inteligencia Artificial (IA), sin mencionar su poderío militar. El problema de esto es que existe el riesgo que decisiones tales como disparar misiles podrían ser tomadas eventualmente por agentes de software. En columnas anteriores hemos hablado de la importancia que tiene una legislación para regular los desarrollos en IA, que involucre la participación de las grandes empresas de tecnologías, así como de los gobiernos.

Recientemente se llevó a cabo en el Reino Unido la denominada declaración Bletchley, con *Bletchley Park* como escenario - lugar donde se decodificaron los mensajes alemanes encriptados durante la segunda guerra mundial - que reunió líderes de países, CEOs, y por supuesto la comunidad científica dedicada al estudio de la IA. La agenda tuvo 5 objetivos: analizar los riesgos que la IA presenta a la humanidad, formalizar esfuerzos internacionales de colaboración, establecer criterios a los que las organizaciones deben ajustarse al desarrollar IA, identificar áreas de colaboración de IA segura, y mostrar cómo el desarrollo de la IA segura impacta de manera global.

Más de 25 países de todo el mundo participaron, incluyendo: EUA, Singapur, Canada, Alemania, China, y Japón, así como el representantes de la ONU, y de la OCDE. De américa latina sólo estuvieron Chile y Brasil. Respecto de los gigantes de la tecnología hicieron presencia: Amazon, Google, Microsoft y OpenAI. Durante el evento, se anunció la creación del Instituto de IA Segura en el Reino Unido, cuyo objetivo es el de asegurarse que las IA emergentes sean seguras. También se anunció que dicho gobierno está invirtiendo 300 millones de libras esterlinas (GBP) para impulsar la IA y crecer 30 veces su tamaño del sector. Para saber más acerca de los riesgos de la IA discutidos en el evento, se puede consultar el artículo*. Para conocer acerca de la IA segura, se puede consultar el reporte de la AI Safety Summit†.

Respecto de América Latina, en un evento realizado en Agosto pasado en Chile, denominado *IA para el desarrollo sostenible de América Latina*, se dieron a conocer los hallazgos respecto de 4 dimensiones : Factores Habilitantes, Investigación, Desarrollo y Adopción y Gobernanza. El Índice Latinoamericano de Inteligencia Artificial ofrece una radiografía completa de los países participantes en el evento : Argentina, Bolivia, Brasil, Chile, Colombia, Costa Rica, Ecuador, México, Panamá, Paraguay, Perú y Uruguay. Participaron también : Amazon, Google, Github, Linkedin, UNESCO, el banco de desarrollo de américa latina, y el banco interamericano de desarrollo. De parte de México, hizo presencia la Academia Mexicana de Computación (AMEXcomp). De esta manera se ha venido conformando una Agenda Digital para América Latina y el Caribe (eLAC), con miras a la Novena Conferencia Ministerial sobre la Sociedad de la Información de América Latina y el Caribe, a realizarse en 2024. Para saber más, se puede consultar‡(ILIA).

En México la inteligencia artificial no ha tenido su ***Boom***, a pesar de los esfuerzos que diferentes sectores de la academia y la iniciativa privada han realizado. Se requiere de un esfuerzo decidido por parte del gobierno para impulsar la IA en nuestro país. En Mayo de este año se introdujo una nueva ley para regular la inteligencia artificial - Ley para la Regulación Ética de la Inteligencia Artificial para los Estados Unidos Mexicanos. El objetivo de esta iniciativa es establecer estructuras y estándares éticos para el desarrollo, investigación, y uso de la IA en Mexico, así como establecer y regular el Consejo Mexicano para la Ética de la Inteligencia Artificial y Robótica. Para saber más acerca de esta iniciativa se puede consultar§.✷

NOTA : Ninguna inteligencia artificial ha sido usada para crear este escrito.

*https://www.gov.uk/government/publications/frontier-ai-capabilities-and-risks-discussion-paper
†https://www.gov.uk/government/publications/emerging-processes-for-frontier-ai-safety
‡https://indicelatam.cl/ficha-pais
§https://es.wired.com/articulos/diputado-presenta-propuesta-de-ley-para-regula-la-ia-en-mexico

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Sakbe

Laura Cruz Reyes, Laura Gómez Cruz y Claudia Guadalupe Gómez Santillán
sakbe@komputersapiens.org

Aplicaciones de la IA: Chatbots generativos

Los chatbots que usan la inteligencia artificial generativa son sistemas de procesamiento de lenguaje natural (PLN) que incluyen alguna técnica de redes neuronales o aprendizaje profundo, y así construyen sus respuestas durante las interacciones con los usuarios, sus respuestas no son predeterminadas, sino que en cada interacción generan nuevas respuestas acorde al contexto de la conversación y la información disponible.

Este tipo de sistemas han tenido un gran avance en los últimos años, sus contribuciones impactan en el procesamiento de lenguaje natural ya que usan modelos lingüísticos para generar desde imágenes hasta música a partir de una palabra. Sin embargo, en la actualidad se presentan desafíos importantes como la posibilidad de generar respuestas inapropiadas, por lo que estos sistemas se siguen mejorando con el fin de garantizar una interacción segura y afectiva con los usuarios. Algunos ejemplos de estos sistemas son:



ChatGPT ⇒ El ChatGPT de OpenAI podría ser definido como un "robot informático" que cuenta con infinidad de temas para consultar, esto lo hace mediante su interfaz que es de fácil manejo para el usuario. A este robot se le pueden solicitar datos, análisis e incluso una opinión. Las respuestas serán generadas mediante el análisis estadístico de miles de millones de textos en Internet. GPT significa Transformador Generativo Preentrenado (Generative Pre-trained Transformer) y pertenece a la familia de modelos de lenguaje natural desarrollados por la Inteligencia Artificial (IA) abierta.

https://chat.openai.com/



Bing Chat ⇒ Otro chatbot generativo es el Bing Chat de Microsoft. Había permanecido relegado ya que necesitaba mejorar en algunos aspectos de sus funciones como son las búsquedas de información, y además Microsoft le incluyó una nueva función de Chat que usa GPT-4 gratis, que es la versión más avanzada del motor de IA GPT-4, más avanzado que el de ChatGPT y que puedes usar pagando con ChatGPT Plus, esto permitirá hacer búsquedas complejas con un formato conversacional.

https://www.microsoft.com/es-es/bing?ch&form=MA13FV



Google BARD ⇒ Google BARD es un servicio de chat que funciona de manera similar a ChatGPT, pero BARD extraerá su información de la web siempre en todas sus versiones. Este chat esta basado en el lenguaje de modelado para aplicaciones de modelado (LaMDA, Language Model for Dialogue Applications) que es un potente modelo de lenguaje experimental diseñado por Google para aplicaciones de diálogo.

https://bard.google.com/

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Ajedrez computacional: ¿cómo la inteligencia artificial se convirtió en la campeona del mundo?

María Fernanda Castro Sandoval y Edgar Alejandro Guerrero Arroyo

El ajedrez computacional y su papel en la historia de la humanidad

Se estima que en el siglo VI d.C. surgió un juego en la actual India llamado *chaturanga*, considerado el antecesor del ajedrez. Contaba con piezas de marfil que representaban las unidades de un ejército: infantería, caballería, elefantes y carros. Luego se popularizó durante la Edad Media, cambiando su estructura según los ejércitos de cada época y lugar y, en la Europa del siglo XV, tomó su forma actual. Cuatro siglos después, surgieron los primeros campeonatos mundiales y desde entonces se han ido desarrollando nuevos estilos de juego. Algunos de los acontecimientos más importantes que han marcado su historia se presentan en la Figura 1.

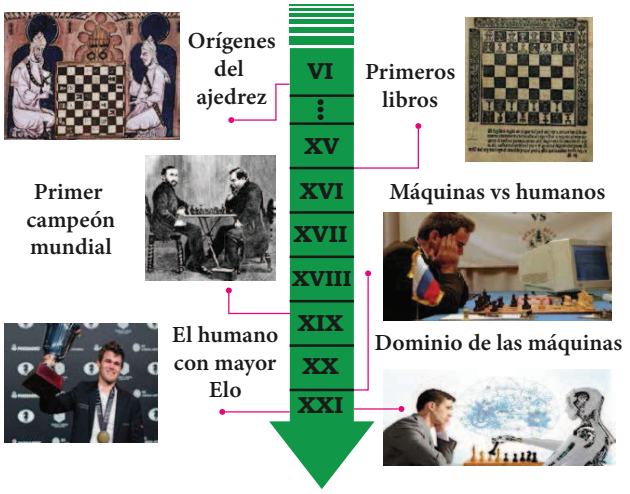


Figura 1. La huella del ajedrez en la historia.

Durante el siglo pasado, a finales de la década de los 50's, el profesor estadounidense Árpád Imre Élö puso de moda el sistema ELO, el cual es un sistema de puntuación comúnmente utilizado hoy en día que permite cuantificar la fortaleza ajedrecística que posee un jugador.

En la misma época, comenzaban a desarrollarse las primeras computadoras, y sorprendentemente, casi al mismo tiempo surgieron los primeros algoritmos que jugaban ajedrez contra humanos, pero su habilidad era muy limitada. En 1968, el Maestro Internacional David Levy apostó que "ninguna computadora lo vencería en diez años"; y ganó, porque hasta finales de la década de 1980, estas comenzaron a vencer a los mejores jugadores.

Después mejoraron al grado que, en 1997, la computadora Deep Blue venció por primera vez a un campeón mundial: Garry Kasparov. Actualmente existen máquinas que superan ampliamente a Deep Blue y, por ende, a cualquier campeón humano: como *Stockfish* o *Komodo*. Pero en 2017 llegó AlphaZero, una máquina que funciona mediante aprendizaje con refuezo y, a cuatro horas de ser programada sólo con las reglas del juego, fue capaz de aprenderlo y vencer a los mejores programas de ajedrez.

Estas máquinas contribuyen significativamente a la enseñanza de este juego. Gracias a ellas se puede practicar de manera mucho más fácil y eficaz que hace cien años. Como se plantea en [4], al combinar nuestra experiencia humana con la velocidad de cálculo de una computadora, podemos corregir errores, encontrar soluciones y perfeccionar nuestra técnica.

Y como lo plantea Kasparov en su libro *Cómo la vida imita al ajedrez*, usualmente los problemas cotidianos pueden resolverse aplicando el mismo razonamiento lógico que al jugar ajedrez. Así, un buen ajedrecista sabe cómo resolver problemas y enfrentarse a la vida.

Pero ¿cómo funcionan estas máquinas? ¿Cuál es el razonamiento que siguen para poder jugar?

A continuación lo respondemos.

El modelo tradicional

1. Representar el tablero del juego y sus piezas dentro de la computadora.

Primero se debe relacionar el tablero y cada pieza con objetos que una computadora pueda almacenar e interpretar. Así establecemos una comunicación humano-máquina donde le proporcionamos el material de juego.

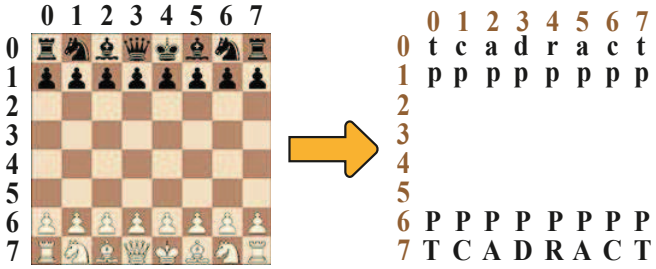


Figura 2. Representación del tablero como una matriz.

Para esto, existen varias estructuras de datos que resultan útiles. La más ilustrativa es el uso de letras para

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

representar las piezas, por ejemplo, asignar R para el rey, y T, C, A, D y P para la torre, caballo, alfil, dama y peón, respectivamente. Además, podemos asignar letras mayúsculas a las piezas blancas, y minúsculas a las negras (o viceversa). Para representar el tablero, podemos utilizar una matriz que contenga letras en el mismo orden en el que están posicionadas en el tablero, como lo muestra la Figura 2.

2. Generar un árbol de jugadas en cada turno.

Una vez representada una posición dada, se identifican y enlistan todos los posibles movimientos que el jugador de piezas blancas (la máquina en nuestro caso) pueda realizar y, para cada uno de ellos, todas las formas en que su rival le puede responder, como se muestra en la Figura 3, generando así un árbol de posibles jugadas.

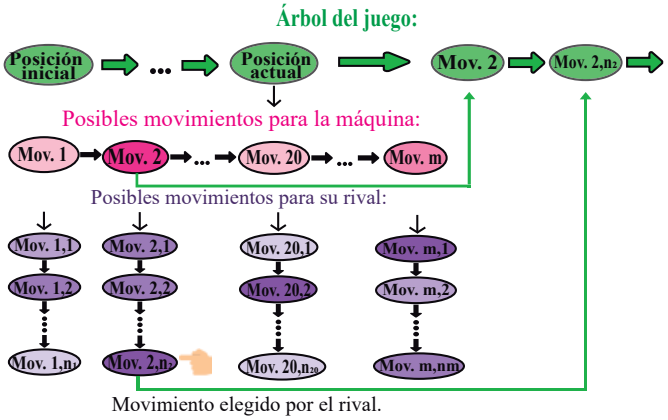


Figura 3. El árbol de jugadas.

3. Evaluar cada posible jugada.

Para saber cuál movimiento elegir, influyen las reglas de juego que contenga el programa. Estas le asignarán un valor numérico a cada posible movimiento de la computadora, que reflejará lo conveniente que sería ejecutarlo si se desea ganar.

4. Encontrar el mejor movimiento y realizarlo.

Cuando los movimientos estén evaluados, la máquina buscará aquel con el mayor puntaje y lo jugará. Si varios tienen ese puntaje, tomará entre ellos uno al azar.

Esto parece sencillo, pero cuando se logra que el programa visualice más movimientos a futuro, el árbol de jugadas se torna más ancho y profundo, resultando más difícil encontrar dicho movimiento.

A continuación analizaremos más detalladamente los últimos 3 puntos.

Generación de movimientos: ¿qué puedo mover y qué puede hacer mi rival?

El juego comienza con una posición inicial, ilustrada en la Figura 2. A partir de aquí, si por ejemplo la computadora jugara con las piezas blancas, en cada turno de estas hará lo siguiente: como se observa en la Figura 3, para la posición actual de las piezas la máquina identificará todos los movimientos que pueda ejecutar de manera que cumpla las reglas del juego.

Para cada uno de estos movimientos, creará una matriz que represente al tablero con la pieza movida (es decir, donde su letra correspondiente aparezca en su lugar de destino). Estas representaciones se almacenarán formando una lista dentro de la computadora (ilustrada con color rosa en la Figura 3). Luego, para cada movimiento de la lista, la computadora identificará todos los movimientos que pueden hacer las piezas negras en respuesta; los representará y almacenará en listas adicionales (que se ilustran de color morado en la Figura 3).

Pero ¿cómo sabe la computadora cuáles movimientos puede hacer?

Las reglas para mover cada pieza se pueden definir con sumas y restas. Veamos un ejemplo: en la Figura 4 hay piezas colocadas de forma arbitraria, y resaltan dos de ellas: un caballo y la dama blanca. Tomando el número de fila y luego de columna de una pieza, podemos construir sus coordenadas.

Entonces en general, una dama con coordenadas (i, j) puede moverse a $(i-1, j)$, $(i-2, j)$, etcétera, hasta topar con otra pieza (letra). De igual manera puede moverse a $(i-1, j+1), (i-2, j+2)$, etcétera; y análogamente hacia las demás direcciones en las que el juego admite que se mueva. ¡Así podemos construir sus movimientos!

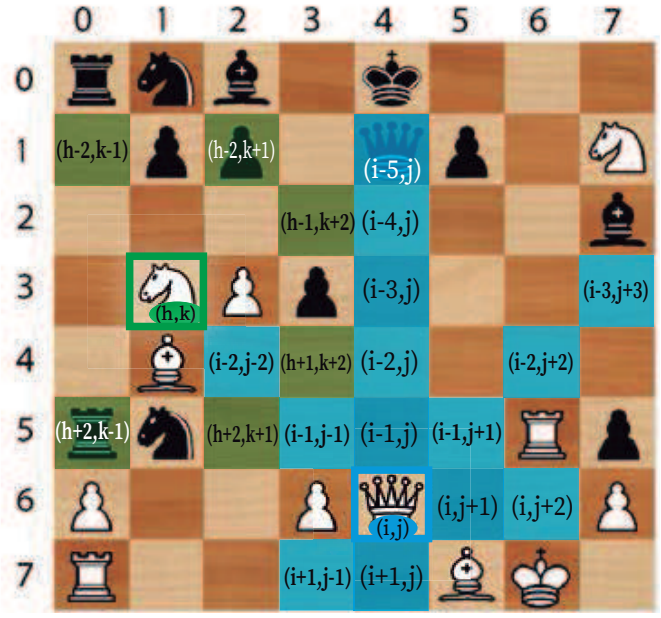


Figura 4. Generación de movimientos.

Para las demás piezas se utiliza el mismo razonamiento. Por ejemplo, los movimientos de un caballo se pueden escribir como $(i \pm 2, j \pm 1)$ ó $(i \pm 1, j \pm 2)$.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Siguiendo solo 4 simples reglas se puede alcanzar un ELO de casi 900 puntos, los mismos que un jugador de club medio según la FIDE.

Para verificar en cada matriz si el rey está en *jaque*, se pueden buscar amenazas alrededor de este, por ejemplo, en direcciones adyacentes buscar torres o la dama, en las diagonales alfiles o la dama, etc.

Es razonable pensar que si para cada respuesta de las piezas negras, generamos de nuevo todos los posibles contraataques de las blancas, y así continuamos generando las posibles réplicas de ambos jugadores hasta la victoria de alguno (es decir, crear más niveles de profundidad en el árbol de jugadas), entonces el programa siempre podría encontrar el camino para ganar.

Sin embargo, conforme el juego avanza, la cantidad de movimientos posibles crece exponencialmente, como lo vemos en la siguiente tabla para los primeros turnos partiendo de la posición inicial:

Turno (para un jugador)	Número de movs. posibles
1	20
2	400
3	8 902
4	197 281
5	4 865 609
6	119 060 324
7	3 195 901 860
8	84 998 978 956
9	2 439 530 234 167
10	69 352 859 712 417

Esto determinaría un árbol de jugadas tan inmenso, que ninguna computadora actual podría manejarlo (ni en memoria ni en tiempo).

Por lo tanto, actualmente las máquinas solo analizan entre 20 y 30 niveles de profundidad (movimientos a futuro), mientras que el mejor ajedrecista humano, Magnus Carlsen, afirma ver entre 15 y 20, pero solo para unas pocas variantes.

Evaluación de una posición: ¿voy ganando o perdiendo?

Una vez generado el árbol de jugadas, debemos analizar cada una de sus ramas para saber cuál seguir. Para esto, se mencionó que los programas poseen un conjunto de reglas que indican cuán conveniente es una jugada, asignándole una puntuación numérica.

Estas reglas son diseñadas por un equipo de ajedrecistas y programadores: los primeros indican la importancia de los elementos en una posición, y los segundos estructuran y codifican este conocimiento para que la computadora lo pueda replicar.

Por ello, estas reglas pueden variar en cada máquina, e incluso en cada ajedrecista, ya que son producto de su intuición y experiencia.

A manera de ejemplo, consideremos algunas reglas que los autores hemos estado trabajando:

Regla zero

Como se observa en la Figura 5, esta regla califica con 0 puntos a todos los movimientos, excepto aquellos donde se da o se recibe *jaque* mate, que obtienen 100 y -45 puntos respectivamente.

Así, esta regla equivale a jugar al azar, conociendo sólo las reglas del ajedrez.

Regla de capturas

Además de calificar de esa forma los movimientos para dar o recibir *jaque mate*, esta regla suma puntos por capturar piezas, o los resta por perderlas. Para ello, les asigna un valor numérico: la dama vale 9 puntos, la torre 5, caballo y alfil valen 3, y los peones 1 punto. Así, la calificación de un movimiento será la resta de la pieza que capture la máquina menos aquella que capture su rival.

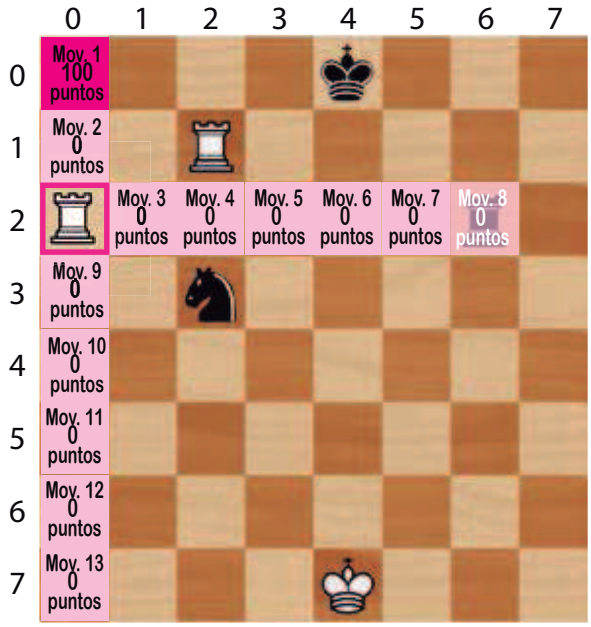


Figura 5. Evaluación con la regla zero.

Por ejemplo, en la Figura 6 notemos que la torre blanca de (7,0) se encuentra amenazada por el caballo (5,1). Entonces, aquellos movimientos donde la dama (6,4) no capture pero luego pueda ser capturada, valen: 0-9=−9 puntos. Pero aquellos donde no capture y tampoco pueda ser capturada, valen: 0-5=−5 puntos, ya que la torre

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

sí podría ser tomada. Finalmente, si el caballo (3,1) toma al peón (1,2) dando *jaque* al rey negro, el rival no podría capturar ninguna pieza, solo mover a su rey; por ello este movimiento tiene: 1-0=1 punto, el cual es el mejor movimiento que el programa puede realizar en la posición.



Figura 6. Evaluación con la regla de capturas.

Regla de empate

Como lo dice su nombre, esta regla identifica en la lista a aquellos movimientos que producirán un empate por rey ahogado e inicialmente los deja sin calificar. Una vez que ha calificado a los demás con la regla anterior, encuentra en el movimiento con mayor puntuación, al jugador que lleve más ventaja, sumando los puntos de las piezas que posea cada uno. Si la computadora obtuvo más puntos, entonces un empate no le resulta favorable, ya que podría ganar; por ello, los movimientos que conllevan a un empate tendrán una calificación de -40 puntos. Por el contrario, si la máquina va perdiendo, entonces el empate podría ser su mejor opción; por lo tanto estos movimientos tendrían un puntaje de 95.

La computadora identifica un empate o un *jaque mate* cuando se tiene un movimiento *hoja* en el árbol de jugadas; esto es, un movimiento al que ya no le corresponde ninguna lista de contramovimientos, porque ya no le quedan respuestas posibles a uno de los jugadores. En este caso, si el rey del jugador que ya no puede responder se encuentra en *jaque* (en el movimiento *hoja*), quiere decir que este ha perdido (*jaque mate*). En caso contrario, se tienen *tablas* por *rey ahogado*.

Regla del dominio

Incluyendo a las reglas anteriores: cuando se tiene el puntaje por capturas de un movimiento que no determinará un empate, se le suma un pequeño número decimal que refleja cuánto controlan el tablero las piezas. Para calcularlo: se asigna un valor numérico a cada casilla, y cuanto más al centro esté, vale más; entonces calculamos la cantidad $\frac{DB-DN}{2000}$, donde DB y DN son sumas de las casillas que dominan (a las que se pueden mover) las piezas blancas y negras respectivamente, y se divide entre 2000 para que la cantidad resulte menor a 1.

Así, vemos que en la Figura 7 la dama negra seguramente dará *jaque*, pero con esta regla la computadora sabe que el mejor movimiento es el del alfil, porque además de evitar el *jaque*, otorga a las piezas blancas un mayor control del tablero.



Figura 7. Evaluación con la regla del dominio.

Con estas simples reglas y, generando solo dos movimientos a futuro en cada turno (los de las blancas y las posibles respuestas de las negras), hemos construido una máquina con un nivel de principiante (casi 900 puntos de ELO), como vemos en la Figura 8.

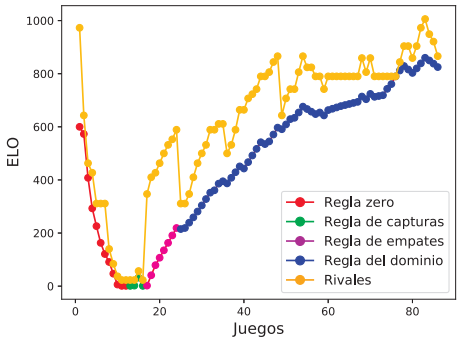


Figura 8. Evolución de nuestra máquina tradicional con cada regla.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

El motor del modelo tradicional: el algoritmo minimax y la poda alfa-beta

Las reglas anteriores solo evalúan a los movimientos que son *hojas* en el árbol de jugadas, para saber qué tan favorecedor es el desenlace después de ejecutar 20 ó 30 movimientos específicos.

Así, veamos la estructura en la Figura 9, que representa el puntaje de los nodos del árbol de jugadas, donde cada círculo simboliza un posible movimiento de las piezas blancas y cada cuadrado, uno de las negras; asimismo, el número que contiene cada figura corresponde a la calificación del movimiento.

Inicialmente solo los cuadrados del nivel 0 tendrían un valor. Será nuestra tarea deducir la calificación del movimiento verde con sólo esa información.

Para ello se utiliza el algoritmo **minimax**, que funciona así: una vez que los movimientos del nivel 0 estén calificados, asumiremos que el oponente siempre elegirá entre sus movimientos aquél con la mínima puntuación, ya que todas las calificaciones reflejan el beneficio para las blancas. Así, el mínimo de cada grupo de cuadrados en el nivel 0, pasará a ser el valor de cada círculo del nivel 1. Contrariamente, la computadora siempre elegirá el movimiento con la mayor puntuación, ya que juega con las piezas blancas. Entonces, el máximo de cada grupo de círculos del nivel 1 será el valor de cada cuadrado del nivel 2. La misma idea continua para los niveles superiores. En resumen: el algoritmo minimax permite calificar un movimiento inmediato (nodo verde) a partir de toda la información de los movimientos posibles a partir de este (todos los nodos de los niveles 2 y menores).

Este algoritmo tiene una desventaja: tarda demasiado cuando el árbol de jugadas es muy grande.

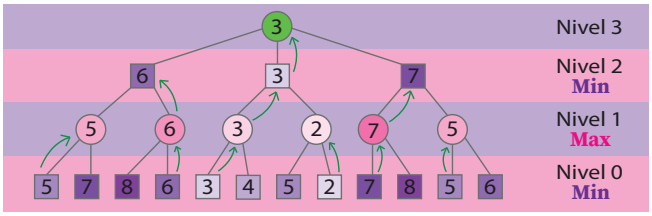


Figura 9. El algoritmo minimax.

Por ello, existe una mejora llamada **poda alfa-beta**, que restringe la búsqueda a solo ciertas ramas de jugadas, de esta manera: supongamos que en la Figura 10 queremos calcular el valor del movimiento verde, y para hacerlo escogeremos al mínimo de sus movimientos *hijos*, pero de ellos solo conocemos los valores 6 y 3, es decir, nos falta determinar el 7, por lo que revisamos a los hijos de este para tomar el máximo. Vemos que el primero de ellos es un 7, por lo que el valor en # será 7 ó mayor. Pero como en el grupo donde está # se elegirá al mínimo, y ahí se encuentra un 3, entonces no necesitamos revisar al resto de *hijos* de #, ya que no mejorarán el resultado para el nodo verde. La misma idea aplica para descartar al movimiento con un 6 en la esquina inferior derecha del árbol de jugadas.

De este modo se descartan ramas de movimientos, ahorrando tiempo de cálculo sin afectar el resultado.

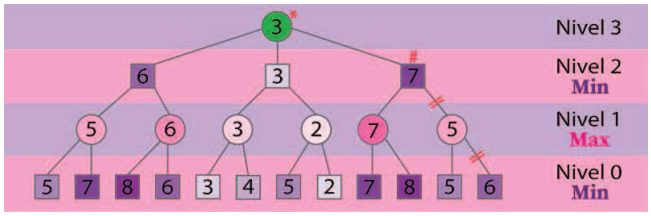


Figura 10. La poda alfa beta.

El rival a vencer

Además del modelo tradicional, hoy en día destaca otro enfoque: el de aprendizaje por refuerzo. Se trata de un modelo de inteligencia artificial inspirado en la psicología conductual que se basa en hacer jugar a la máquina reiteradas veces, asignándole alguna forma de *premio* si gana, o *penalización* si pierde, incitando que prefiera las victorias y así aprenda a jugar.

Las máquinas con este modelo, como *Leela Zero* o *Alpha Zero* utilizan redes neuronales artificiales en lugar de las reglas heurísticas para evaluar, y emplean algoritmos de búsqueda diferentes a minimax, como los árboles de Monte Carlo (MCTS). Además, ellas aprenden de su propia experiencia, mientras que las de enfoque tradicional aprenden con reglas que reflejan la experiencia de sus creadores.

Este modelo ha resultado tan exitoso como el tradicional, teniendo a sus máximos representantes compartiendo el podio de los mayores ELOs de la historia junto con grandes exponentes del modelo tradicional como *Stockfish* y *Komodo* (ilustrado en la Figura 11).



Figura 11. El podio de ELOs.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Conclusiones

Contamos con más de medio siglo de trabajo continuo por parte de programadores y ajedrecistas que analizan nuevas formas de mejorar la capacidad de estas máquinas; las cuales cambiaron por completo la forma de interactuar con el ajedrez.

Actualmente los aficionados disfrutan de jugar contra ellas, pueden jugar contra personas al otro lado del mundo, estudiar sus jugadas, y hasta ver partidas en directo. Entender cómo las máquinas juegan ajedrez puede ayudar a que los jugadores humanos mejoren en su juego, ayudar a las personas a estructurar su propio pensamiento y a mejorar sus habilidades para la toma de decisiones.✷

Agradecimientos

Agradecemos las facilidades brindadas al proyecto "Modelación y pronóstico de fenómenos físicos mediante redes neuronales artificiales" por parte del Centro de Análisis de Datos y Supercómputo (CADS) de la Universidad de Guadalajara, a través del uso de la supercomputadora Leo Atrox.

REFERENCIAS

1. Lundqvist, M., Carlsson, P., Sjödahl, R., et al. (2017). Patient benefit of dog-assisted interventions in health care: a systematic review. *BMC complementary and alternative medicine*,17, 1-12.
2. Besser, A. y Zeigler-Hill, V. (2014). Positive personality features and stress among first-year university students: Implications for psychological distress, functional impairment, and self-esteem. *Self and identity*, 13(1), 24-44.
3. Blackwell, E.J., Twells, C., Seawright, A., et al. (2008). The relationship between training methods and the occurrence of behavior problems, as reported by owners, in a population of domestic dogs. *Journal of Veterinary Behavior*, 3(5), 207-217.
4. Rooney, N. J. y Cowan, S. (2011). Training methods and owner–dog interactions: links with dog behaviour and learning ability. *Applied Animal Behaviour Science*, 132(3-4), 169-177.
5. Fugazza, C. y Miklósi, Á. (2014). Should old dog trainers learn new tricks? The efficiency of the Do as I do method and shaping/clicker training method to train dogs. *Applied Animal Behaviour Science*, 153, 53-61.
6. Blanchard, A. y Taddeo, M. (2023). The Ethics of Artificial Intelligence for Intelligence Analysis: a Review of the Key Challenges with Recommendations. *Digital Society*, 2(1), 1-28.
7. Bibal, A., Lognoul, M., De Streel, A., et al. (2021). Legal requirements on explainability in machine learning. *Artificial Intelligence and Law*, 29, 149-169.
8. Mancini, C. (2011). Animal-computer interaction: a manifesto. *Interactions*, 18(4), 69-73.
9. Rodríguez-Vizzuett, L., Espinosa-Curiel, I.E. y Pérez-Espinosa, H. (2023). Digital Technology Supporting the Remote Human-Dog Interaction: Scoping Review. *Animals*, 13(4), 699-721.
10. Abrego-Ulloa, E.R., Aguilar-Lazcano, C.A., Pérez-Espinosa, H., et al. (2022). Towards a monitoring and emergency alarm system activated by the barking of assistant dogs. *In Proceedings of the Ninth International Conference on Animal-Computer Interaction*. Newcastle upon Tyne, United Kingdom, 1-10.

SOBRE LOS AUTORES



María Fernanda Castro Sandoval es una estudiante de la Licenciatura en Matemáticas en el Centro Universitario en Ciencias Exactas e Ingenierías CUCEI, de la Universidad de Guadalajara. Se encuentra trabajando en su proyecto de tesis dirigido por el Dr. Edgar Alejandro Guerrero, orientado en la solución de ecuaciones diferenciales mediante el uso de Redes Neuronales profundas. Sus áreas de interés incluyen a los métodos numéricos, Machine Learning y ciencia de datos.



Dr. Edgar Alejandro Guerrero Arroyo recibió el grado de Doctor en Ciencias de la Computación en el Centro de Investigación en Matemáticas, CIMAT, en el 2016. Es profesor de tiempo completo en el Departamento de Matemáticas, del Centro Universitario en Ciencias Exactas e Ingenierías CUCEI, de la Universidad de Guadalajara. Sus líneas de investigación se centran en modelación numérica de ecuaciones diferenciales, optimización numérica y ciencia de datos.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Descifrando emociones: clasificación de la soledad en diabéticos usando auto-machine learning

Luis Eduardo Maldonado-López, Alejandro Mateos-Moreno†, Isela Esther Juárez-Rojop, Carlos Alfonso Tovilla Zárate y Eddy Sánchez-DelaCruz

Depresión en pacientes con diabetes

Imagina que vas a una consulta médica de rutina, y tus análisis muestran que ahora perteneces al 15 % de mexicanos con diabetes, esta enfermedad crónica en la que se afecta la producción o el aprovechamiento de la hormona insulina, provocando desequilibrios en los niveles de glucosa en sangre. Entonces, tu médico te receta medicamentos para controlar dichos niveles, te recomienda una dieta específica y realizar ejercicio con regularidad; vamos, nada fuera de lo esperado. Pero te sorprendes cuando también te sugiere mantener un círculo social de apoyo y te propone realizar un test de salud mental, junto a otros cuestionarios.

Seguramente te preguntarías: ¿a qué viene esto del círculo de apoyo? O ¿qué tienen que ver estos cuestionarios con la diabetes? Así que tu médico te explica que, aunque todavía no se comprende completamente la relación entre la diabetes y la depresión, sí han observado cómo un paciente con una enfermedad es más propenso a padecer la otra [1]. Si además de tener diabetes, te sientes solo, o no tienes un grupo social (familia, amigos, etc.) Para ayudarte a sobrellevar los pormenores de tu padecimiento, tendrías mayor probabilidad de desarrollar depresión. Esto sucede debido a que a los pacientes les agota tener que recordar las dosis y horarios de sus medicamentos, además de estresarse por hacerlo frente a familiares y amigos, algunos por pena y otros para evitar explicar los detalles de la enfermedad, o recibir compasión. Aunado a lo anterior, sienten ansiedad al pensar en las afecciones más graves que puede provocar la diabetes, como ceguera o amputaciones, o al pensar en la muerte, pues según el INEGI, en el 2023, la diabetes fue la segunda causa de muerte, después de las enfermedades del corazón.

Entonces, estos pacientes no sólo se aíslan, sino que además presentan cansancio, estrés y ansiedad, es decir, síntomas que en conjunto pueden provocar depresión.

Como consecuencia, los pacientes pierden la energía y el ánimo para seguirse cuidando, ignorando su tratamiento, dieta y ejercicios, y cayendo en un círculo vicioso que les agrava los síntomas de la diabetes (ver Figura 1). Por lo que, en este hipotético caso, tu médico te comenta que están recabando información de las personas con diabetes para identificar a quienes se sientan solos, con el objetivo de prevenir posibles problemas de salud mental.



Figura 1. Círculo vicioso hacia la depresión. Las personas con diabetes que se sienten mal de ánimo, se aíslan de los demás, luego se dejan de cuidar, agravando sus síntomas físicos, eso los deja con aún menos energías y eventualmente caen en depresión.

En este tipo de problemática de salud, la Inteligencia Artificial puede ayudar a los profesionales de la salud. Utilizando la información recopilada en una base de datos, los algoritmos de aprendizaje automático (conocido en inglés como *machine learning*) pueden proyectar qué pacientes con diabetes tienen un mayor riesgo de sentirse solos y determinar los indicadores clave para realizar esta proyección.

En las secciones siguientes, abordaremos primero la construcción de la base de datos, luego describiremos el proceso de limpieza y tratamiento de los datos, seguido de cómo empleamos *software de auto-machine learning* para encontrar el mejor modelo. Después, presentaremos resultados preliminares sobre la clasificación de los niveles de soledad en los pacientes y, por último, reflexionaremos sobre las aplicaciones prácticas de la Inteligencia Artificial en el campo de la salud.

Construyendo la base de datos. Caso: Villahermosa, Tabasco.

De vuelta al consultorio en tu consulta médica completa de control de tu padecimiento, debes contestar cuestionarios. El primero te solicita tus datos generales como: sexo, edad, educación ocupación, etc. En el segundo cuestionario te preguntan sobre las comorbilidades por ejemplo, si padeces enfermedades renales, hepáticas, cardiacas, etc. En otro, te preguntan sobre el tipo de medicamentos para la diabetes que tomas, así como sus dosis y horarios.

†El Dr. Alejandro Mateos-Moreno falleció previo a la publicación de este artículo.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Finalmente, debes responder una serie de cuestionarios especializados para diagnosticar depresión, evaluar la calidad de vida del paciente e incluso sobre intentos de suicidio.

Como podrás imaginarte, las respuestas de estos cuestionarios, en conjunto con tu antropometría, (altura, peso, índice de masa corporal y medidas de cintura y presión arterial) y los análisis de sangre que incluyan tus niveles de glucosa, colesterol, triglicéridos, etc., serán la información que alimente la base de datos. Esto es lo que hicimos en el Hospital Regional de Alta Especialidad "Dr. Gustavo A. Rovirosa Pérez" en Villahermosa, Tabasco, México, donde a lo largo de más de 4 años de investigación, se recopilaron datos de más de 400 personas con diabetes [2].

Con todos los datos, teníamos 187 variables para cada paciente, pero antes de construir un modelo, realizamos un par de pasos importantes, como limpiar y tratar los datos según un objetivo elegido.

Limpiando y explorando los datos

Uno de los cuestionarios anteriormente mencionados, es "Escala de Depresión del *Center of Epidemiological Studies*" (CES-D-R). Dentro del existe una pregunta específica para determinar el nivel del sentimiento de soledad en los pacientes. Dicha pregunta es: "¿En la semana pasada, durante cuantos días me sentía solo(a)?" Las posibles respuestas son:

+ Escasamente (0 a 1 día en la última semana)
+ Ocasionalmente (1 a 2 días en la última semana)
+ Algo (3 a 4 días en la última semana)
+ La mayoría (5 a 7 días en la última semana)
+ Casi diario (10 a 14 días en las últimas dos semanas)

Como esta variable tiene cinco niveles o clases, nuestro problema es entonces una clasificación multi-clase, donde buscamos un modelo capaz de clasificar cada nivel de soledad que siente un paciente con diabetes. Asignamos esta variable como nuestra columna objetivo, a la cual agregamos la respuesta "No clasificado" para los pacientes que no contestaron esa pregunta del cuestionario.

Como deseamos hacer una proyección de dicho sentimiento a partir de los datos clínicos, optamos por eliminar el resto de los cuestionarios de salud mental. Por lo que redujimos el número de variables predictoras (columnas en nuestra base de datos) de 187 a 77.

Es importante señalar que nos proporcionaron los datos sin las columnas de 'Código de identificación', y de 'Iniciales' de los pacientes, que el personal de salud recabó para tratar a los pacientes individualmente, con lo cual preservamos el anonimato de los participantes voluntarios de este estudio.

Debido a que queríamos comparar el desempeño de diversos algoritmos, decidimos hacer un tratamiento a la base de datos para facilitar el procesamiento y la evaluación de los diversos algoritmos. Primero, normalizamos las columnas con datos numéricos mediante la siguiente fórmula:

$$x_n = \frac{(x_i - x_{min})}{(x_{max-xmin})}$$

Donde x_n es el valor normalizado, x_i es el valor inicial observado, x_{min} es el valor mínimo de esa columna y x_{max} es el valor máximo de la misma columna. Haciendo que el valor mínimo para todas las columnas sea de 0, y el máximo de 1 (Figura 2). Así, evitamos que los valores mayores de unas variables opaquen la importancia de otras; por ejemplo, los valores de glucosa iban de 57 a 496 (mg/dl) pero el de porcentaje de hemoglobina hba1c sólo iba de 1.8 % a 21.1 % (este valor es un indicador de los niveles de glucosa de por lo menos las últimas 6 semanas, a diferencia de medir directamente la glucosa que muestra el valor de las últimas horas).

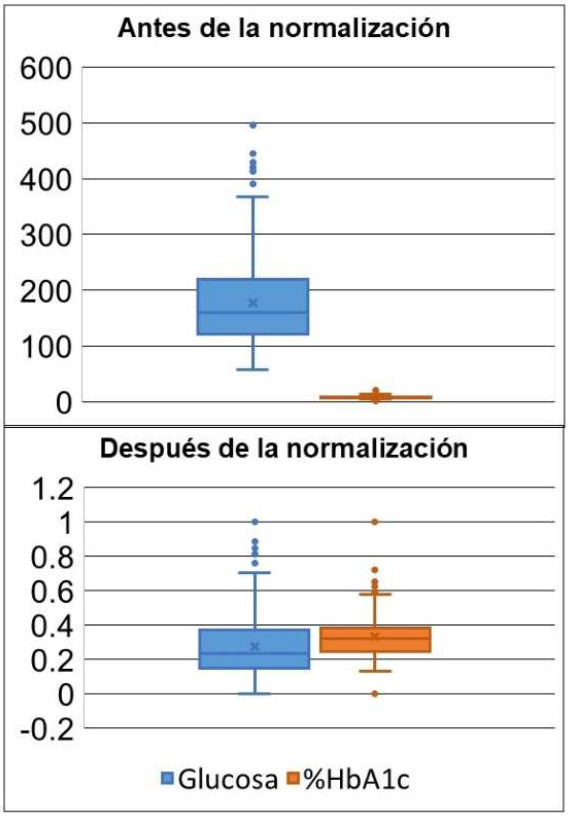


Figura 2. Ejemplo de normalización de variables. Antes de la normalización (arriba) las variables tenían distinta dispersión, después de la normalización (abajo) todas las variables están dentro del mismo intervalo: [0 a 1].

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Después, convertimos los datos categóricos en numéricos, por ejemplo, para la columna sexo, transformamos las respuestas de "Hombre" y "Mujer" a 0 y 1 respectivamente.

Finalmente, ante la ausencia de algunos datos, ya sea porque algunos pacientes no respondieron a todos los cuestionarios o porque no registraron todos los datos de laboratorio, optamos por asignar el valor -1 a las celdas vacías. Indicar la ausencia de datos así, permite al algoritmo procesar la información sin necesidad de eliminar filas con datos incompletos, evitando la pérdida de información.

Al analizar la columna objetivo, encontramos los datos desbalanceados, pues el 60 % de los 446 pacientes habían contestado "Escasamente", sólo un 2 % de datos eran "No clasificado" y el resto de respuestas tenían entre 9 % y 10 % cada una. Posteriormente, realizamos un sub-muestreo, eliminando aleatoriamente algunas filas, pasando de 446 a 381, para que la proporción de pacientes sin sentimientos de soledad fuera equivalente a la suma de pacientes que sí presentaban algún nivel de soledad.

Después de realizar el sub-muestreo, la proporción para la respuesta objetivo quedaría en 200 de los 381 pacientes (52 %) que no tienen sentimiento de soledad, y entre 10 % y 12 % para cada clase de quienes sí lo tienen y el restante 3 % es No clasificado (Figura 3).

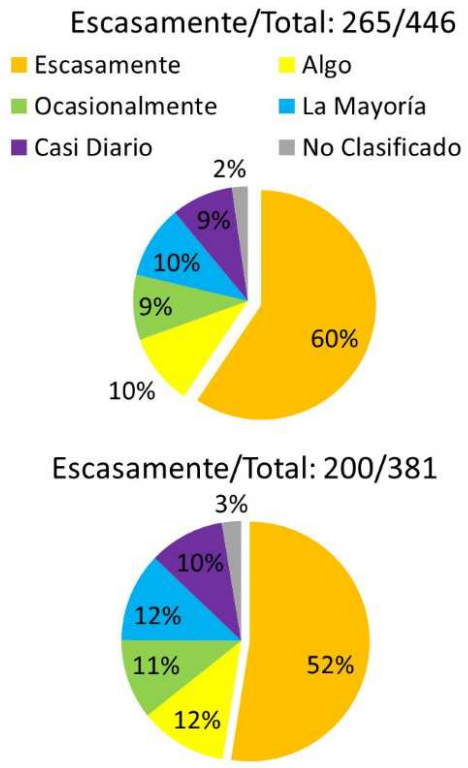


Figura 3. Sub-muestreo de los datos. Se redujo el número de datos de pacientes que no tienen sentimiento de soledad ("Escasamente") para que fuera más comparable con el número de todos los pacientes que sí lo tienen ("Ocasionalmente", "Algo", "La mayoría", "Casi diario").

Paralelamente, construimos otra base de datos agrupando a todos los pacientes que sí tienen sentimiento de soledad, quedándonos con tres clases: Sí: 52 %, No: 45 % y No clasificado:3 %.

Finalmente, dividimos cada base de datos en datos de entrenamiento y datos de prueba. Pero no fue sólo una división, sino cuatro; así un algoritmo se podía entrenar con el 60 %, 70 % o el 80 % de los datos, o bien con el 49.61 % de ellos. Este último valor es el porcentaje de datos que constituyen una muestra estadísticamente representativa (%MR).

Auto-Machine Learning

Con las bases de datos ya procesada, ahora debíamos entrenar un algoritmo de clasificación, para que aprenda las características comunes de quienes sienten soledad y nos permita hacer las proyecciones en nuevos pacientes. Pero, ¿cuál algoritmo seleccionar?, pues existen varios, y con diferentes variables o hiper-parámetros para ajustar y mejorar su desempeño. Pues gracias a la Inteligencia Artificial, un algoritmo aprende no sólo a construir un modelo de clasificación, sino que además se pueden automatizar el entrenamiento y evaluación de múltiples algoritmos simultáneamente, comparando su desempeño para elegir al de menor error de clasificación [3]. Esto se conoce como '*machine learning* automático' o '*auto-machine learning*', y para llevar a cabo esta tarea, empleamos el software *AutoWEKAClassifier*. Dicha herramienta nos permitió evaluar eficazmente cada una de las ocho bases de datos mediante diversos algoritmos de clasificación, agilizando significativamente el proceso.

Resultados preliminares

Para cada base de datos, evaluamos algunas de las medidas de desempeño más ampliamente utilizadas: la exactitud, precisión, la exhaustividad, y *F-score*. La exactitud mejor conocida por su término en inglés *accuracy*, es el porcentaje de los datos clasificados correctamente, la precisión es el porcentaje de los datos que sí pertenecen a una clase asignada por el modelo, la exhaustividad o *recall* es el porcentaje de los datos que pertenecen a una categoría y fueron clasificados correctamente; y finalmente, el *F-score* es una medida que relaciona la precisión con la exhaustividad, y es muy usada en casos donde se tienen más de dos clases, como en nuestro caso [4].

En la Figura 4 mostramos la exactitud para cada una de las particiones de entrenamiento y prueba y para los dos tipos de clasificación de la respuesta objetivo: seis clases (los 5 niveles de soledad, más la respuesta 'No Clasificado' –NC–) o tres clases (Sí, No y NC).

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

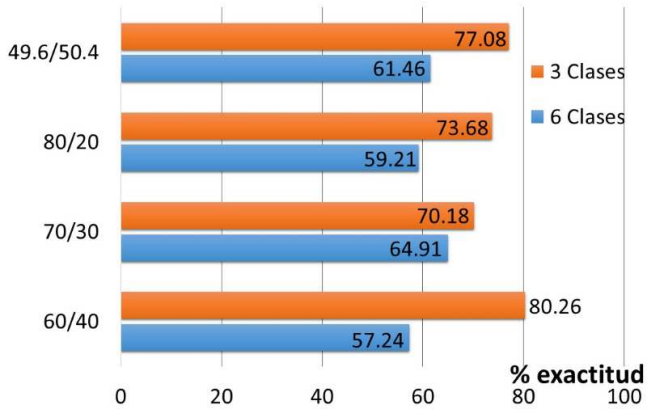


Figura 4.. Porcentaje de exactitud para las diferentes particiones y número de clases. En todos los casos se obtuvieron mejores resultados con sólo tres clases (naranja) en lugar de seis (azul).

Podemos ver un mejor desempeño cuando sólo intenta clasificar tres clases en vez de seis, y en donde para la partición 60/40 se obtuvo el mejor resultado, llegando a 80.26 % de pacientes correctamente clasificados.

AutoWEKA encontró que el mejor algoritmo fue una optimización mínima secuencial (SMO, por sus siglas en inglés) usando un kernel RBF, que es un método de optimización para implementar un algoritmo de máquinas de vectores de soporte (SVM) [5]. Este último es un algoritmo que busca las mejores líneas o fronteras, dentro de espacios matemáticos, capaces de separar a los datos dentro de sus respectivas clases.

Además, también encontró que no todas las variables eran significativas para la clasificación, y el software seleccionó a 25 de las 77. Entonces, al correr de nuevo el algoritmo se mejoró la exactitud hasta un 82.24 %.

En la Tabla 1 mostramos la matriz de confusión, es decir la relación entre la clase real de cada dato y la clase predicha por el algoritmo.

Tabla 1. Matriz de confusión para las condiciones con mejor resultado

Sí	No	NC	<- clasificado como
59	16	0	|real = Sí
11	64	0	|real = No
0	0	2	|real = No clasificado

El algoritmo clasifica correctamente a 125 de 152 datos, y sólo 27 tienen una clasificación errónea. Además, se calculó una precisión de 82.5 % una exhaustividad de 82.2 % y un *F-score* de 0.823. Estos resultados implican un buen desempeño del algoritmo, en el sentido de que los datos provienen de información relativa a personas, lo que implica que siempre habrá mucha dispersión pues cada cuerpo y mente son muy diferentes entre los seres humanos, y aun así se tiene una predicción correcta en 8 de cada 10 pacientes.

Claro que aún buscamos mejorar el modelo para disminuir el número de errores, pues recordemos que los datos son personas, y los errores al clasificar conllevan riesgos; por ejemplo, 11 pacientes clasificados con sentimiento de soledad, en realidad no la presentaron (aproximadamente 1 de cada 7), esto traería el riesgo de sugestionar al médico hacia un padecimiento que no tienes. Por otro lado, 16 pacientes de los 80 clasificados como sin sentimiento de soledad (1 de cada 5), tienen un mayor riesgo porque en realidad sí la presenten, lo que implicaría que no se te brinde la atención necesaria, empeorando tu salud mental y física.

A pesar de lo anterior, recordemos que cualquier algoritmo nunca podrá sustituir a un especialista experto en su campo, sino que será una herramienta para ayudarlo a hacer los diagnósticos más rápidos y comenzar los tratamientos lo antes posible. Entonces, el modelo sólo sugiere, y el médico experto tiene la última palabra, especialmente si se informa el margen de error del algoritmo.

Conclusiones

Nuestro siguiente paso en el proyecto, será ajustar los parámetros del algoritmo para reducir los errores. Además, buscaremos cuáles variables son más importantes, y en qué rango tienen mayor influencia para predecir el sentimiento de soledad. Esto significa que queremos conocer, por ejemplo, si la edad es más importante que el índice de masa corporal (IMC), o si la glucosa en sus valores más altos conlleva a más riesgo que tener un peso elevado. Al final, esta es la información más importante para ti y tu médico, pues con dichos valores se tomarán mejores decisiones relativas a tu salud.

Con la metodología y los resultados de este proyecto, además de mejorar los modelos de *machine learning*, creemos que se puede crear una guía de apoyo para el personal médico, o bien, crear una aplicación móvil en la que los médicos y los pacientes lleven un registro a lo largo de distintas revisiones para llevar el control de la diabetes y de la salud mental. Y en el mejor de los casos, con la información de más pacientes, se podría usar nuestra metodología para analizar las múltiples interacciones entre otras enfermedades crónicas con padecimientos mentales como estrés, ansiedad o depresión.

Finalmente, queremos sugerirte que realmente visites al médico, pues te servirá para tener una idea de tu salud física y mental; y además estarías ayudándonos (a nosotros y a otros especialistas en Inteligencia Artificial) a tener bases de datos más robustas para perfeccionar los modelos de *machine learning*.✷

† En recuerdo de nuestro compañero y amigo el Dr. Alejandro Mateos Moreno. QEPD

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

REFERENCIAS

1. Musselman, L., Betan, E., Larsen, H. y Phillips, L. (2003). Relationship of depression to diabetes types 1 and 2: epidemiology, biology, and treatment. *Biological psychiatry*, 54(3), 317-329.

2. Juárez-rojop, I., Fortuny-Falconi, C., González-Castro, T., Tovilla-Zárate, C., Villar-Soto, M., Sanchez, E. y Rodríguez-Pérez, J. (2018). Association between reduced quality of life and depression in patients with type 2 diabetes mellitus: a cohort study in a mexican population. *Neuropsychiatric disease and treatment*, 14, 2511.

3. Kotthoff, L., Thornton, C., Hoos, H., Hutter, F. y Leyton-Brown, K. (2019). Auto-weka: automatic model selection and hyperparameter optimization in weka. *Automated machine learning*, 81-95.

4. Sammut, C. y Webb, G. (eds.). (2011). Encyclopedia of machine learning. *Springer science & business media*.

5. Platt, J. (1998). Fast training of support vector machines using sequential minimal optimization. En B. Schoelkopf, C. Burges y A. Smola, editores, *Advances in kernel methods - support vector learning*.

SOBRE LOS AUTORES



Luis Eduardo Maldonado López es Ingeniero Químico por la Universidad Juárez Autónoma de tabasco y tiene maestría y doctorado en Nanociencias y Materiales por el Instituto Potosino de Investigación Científica y Tecnológica. Actualmente realiza una estancia posdoctoral en el cuerpo académico de Inteligencia Artificial del TecNM, campus Misantla.



Alejandro Mateos Moreno (QEPD) estaba adscrito como posdoctorante en el Instituto Tecnológico Superior de Misantla, Veracruz, México. Se graduó como Doctor, en Investigaciones Cerebrales por la Universidad Veracruzana, Xalapa, Veracruz, México, y como Químico Farmacéutico Biólogo por la Universidad Veracruzana, Xalapa, Veracruz, México. Se encontraba trabajando en el análisis de datos para el desarrollo de algoritmos para predecir enfermedades neurodegenerativas.



Isela Esther Juárez Rojop es Doctora en Investigación en Medicina por el Instituto Politécnico Nacional, cuenta con el nivel 2 del Sistema Nacional de Investigadores, actualmente es profesora-investigadora de la División Académica de Ciencias de la Salud en la Universidad Juárez Autónoma de Tabasco. Tiene gran experiencia investigando en las áreas de: diabétes, genética y neurociencias.



Carlos Alfonso Tovilla Zárate es Doctor en Ciencias Genómicas por la Universidad Autónoma de la Ciudad de México, pertenece al Sistema Nacional de Investigadores, donde ha sido reconocido con el nivel 3, actualmente es profesor-investigador de la División Académica Multidisciplinaria de Comalcalco en la Universidad Juárez Autónoma de Tabasco. Sus áreas de interés son los meta-análisis de psiquiatría, genética y suicidio.



Eddy Sánchez-DelaCruz es Doctor en Sistemas Computacionales por La Universidad del Sur, Maestro en Sistemas Computacionales y Licenciado en Informática Administrativa por la Universidad Autónoma de Tabasco. el Dr. Sánchez-DelaCruz es miembro del Sistema Nacional de Investigadores, nivel I, miembro de la Sociedad Mexicana de Inteligencia Artificial, miembro de la RedICA-CONACYT, perfil deseable PRODEP y fundador y líder del cuerpo académico Inteligencia Artificial. sus intereses de investigación son el aprendizaje automático y la ciencia de datos con un enfoque multidisciplinario.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Reconocimiento de brócoli mediante la anotación automática en imágenes RGB-D

Ricardo Ángel Álvarez Macedo, José Luis López Díaz, Héctor Alejandro Montes Venegas, Rosa María Valdovinos Rosas y José Raymundo Marcial Romero

El etiquetado o la anotación de datos para entrenar modelos de clasificación implica el manejo de grandes cantidades de información, además es una tarea ardua y tediosa que representa uno de los cuellos de botella en el entrenamiento de sistemas de aprendizaje automático. En este trabajo se propone mejorar el etiquetado o la anotación de plantas de brócoli de una manera semiautomática, lo que incrementará la disponibilidad de datos para la experimentación y evaluación de sistemas de detección y localización automáticos. Para ello, se utilizó un algoritmo de extracción de grupos basado en distancia Euclidiana y se realizó la estimación de características para cada nuevo grupo, lo que permite determinar la similitud entre grupos ya detectados y grupos extraídos de observaciones posteriores. Las pruebas realizadas en conjuntos de datos tomados en campos de cultivo de brócoli del Reino Unido mostraron que la detección y anotación semiautomática de brócoli permite reducir el tiempo que se requiere en el etiquetado de datos.

Introducción

La agricultura desempeña un papel importante en la economía mundial, al ser el sustento imprescindible de las personas, proporcionar alimentos, materias primas y generar empleo en todo el mundo, especialmente en las zonas rurales. Sin embargo, la agricultura también enfrenta muchos desafíos, como el cambio climático, la degradación del suelo, la escasez de agua y la pérdida de biodiversidad.

De forma particular, el cultivo de hortalizas juega un papel fundamental en la alimentación humana y dentro de ellas se encuentra el brócoli o *Brassica oleracea varitalica*, que ha ganado popularidad en los últimos años debido a sus propiedades nutricionales. Su consumo frecuente ha sido recomendado, ya que podría reducir los riesgos de diabetes, anemia y algunos tipos de cáncer debido a algunos compuestos químicos anticancerígenos conocidos como *glucosinolatos*.

En su constitución, el brócoli está formado por una parte comestible (cabeza floral), una masa densa de yemas florales, que es una agrupación de flores inmaduras.

Dependiendo del país de producción, las pérdidas de cultivo ascienden a un 10 % y un 40 %, que pueden ocurrir en la manipulación, almacenamiento, empaque, envío, comercialización, consumo y por cosecha tardía, siendo ésta última la principal causa [1]. En el caso de la recolección de pellas maduras de brócoli, se debe efectuar en un plazo muy breve de tiempo, ya que las inflorescencias mantienen su estado óptimo de corte en tan solo dos días. Después de este periodo, la calidad se reduce, por lo que el personal de la cosecha debe estar preparado y entrenado para reconocer visualmente las plantas listas para cosechar y realizar el corte adecuadamente.

Últimamente, se ha observado una creciente automatización en la agricultura a través de Inteligencia Artificial (IA) y Sistemas Robóticos. Esto se debe principalmente a los avances que los algoritmos *Machine Learning* tienen en la detección y clasificación de elementos.

Lo anterior representa un cuello de botella ya que la recolección de datos es casi automática, mientras que la anotación de datos es mucho más lenta al realizarse comúnmente de forma manual [2].

Algunas aplicaciones en tecnologías agrícolas como la detección y recolección automática de frutos o cultivos utilizan sensores que capturan el color y su mapa de profundidad (conocido como imágenes RGB-D, Red-Green-Blue-Depth, por sus siglas en inglés).

Es común que una imagen RGB-D sea convertida y almacenada como una nube de puntos para su posterior procesamiento por medio de herramientas como PCL (*Point Cloud Library*, por sus siglas en inglés,) o Open3D, que ofrecen una variedad de algoritmos para la percepción 3D [3].

Blok et al. [4] implementaron un algoritmo de aprendizaje que puede estimar el tamaño de las cabezas de brócoli bajo condiciones de oclusión en imágenes RGB-D usando ORCNN (*Occlusion Region-based Convolutional Neural Network*, por sus siglas en inglés). Estos resultados fueron comparados con una Mask R-CNN (*Mask Regional Convolutional Neural Network*, por sus siglas en inglés), donde detectaron y estimaron el tamaño de 229 de las 232 cabezas de brócoli cosechables de tres variedades diferentes [5]. De igual modo, Kusumam et al. [6] describen un sistema de visión para la detección de brócoli utilizando sensores RGB-D, aprendizaje automático y métodos de filtrado temporal para la detección de cabezas de brócoli.

Por otro lado, Louedec et al. [7] hacen uso de la información 3D para detectar cabezas de brócoli basado en CNN (*Convolutional Neural Network*, por sus siglas en inglés). Así mismo, el trabajo realizado por Montes et al. [8] proponen dos métodos para procesar datos 3D

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

que detectan de manera eficiente cabezas de brócoli en tiempo real.

En este artículo se presenta un método basado en la anotación interactiva de datos en imágenes RGB-D para el reconocimiento del brócoli con la mínima intervención humana posible, mejorando el proceso de selección de los puntos en la notación manual.

Metodología

Los experimentos presentados en este artículo fueron implementados utilizando PCL sobre una serie de datos RGB-D tomadas por un Kinect 2 (1920×1080 de resolución RGB y 512×424 de resolución de profundidad) disponibles públicamente*. El método propuesto consta de 5 etapas (Figura 1).

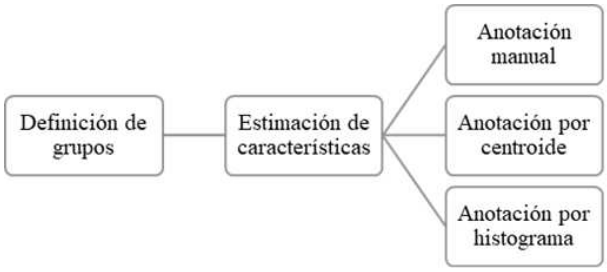


Figura 1. Diagrama del método para anotación de brócoli. Fuente: Elaboración propia.

Etapa de agrupamiento

Algorithm 1: EuclideanClusterExtraction

```
Data: points, tolerance, minSize, maxSize
Result: clusters
clusters ← [];
foreach point in points do
    closestCluster ← None;
    foreach cluster in clusters do
        if distance(point, cluster[0]) < tolerance then
            closestCluster ← cluster;
            break;
        end
    end
    if closestCluster is None then
        clusters.append([point]);
    end
    else
        closestCluster.append(point);
    end
end
foreach cluster in clusters do
    if len(cluster) < minSize or len(cluster) > maxSize then
        clusters.remove(cluster);
    end
end
return clusters;
```

Figura 2. Algoritmo de extracción de grupo basado en la distancia euclidiana. Fuente: Elaboración Propia.

El *clustering* busca agrupar y recolectar datos relevantes, centrándose en identificar las cabezas de brócoli presentes en la nube de puntos. Para lograr esto, se utiliza la extracción de grupos basado en la distancia euclidiana (ver Figura 2).

Donde *points* son los puntos de la nube de puntos, *tolerance* es la distancia máxima que dos puntos pueden tener para considerarse parte del mismo grupo, *minSize* y *maxSize* donde indican el tamaño mínimo y máximo de puntos que puede tener un grupo y si no se cumple es descartado, este valor también se determinó empíricamente (Figura 3).

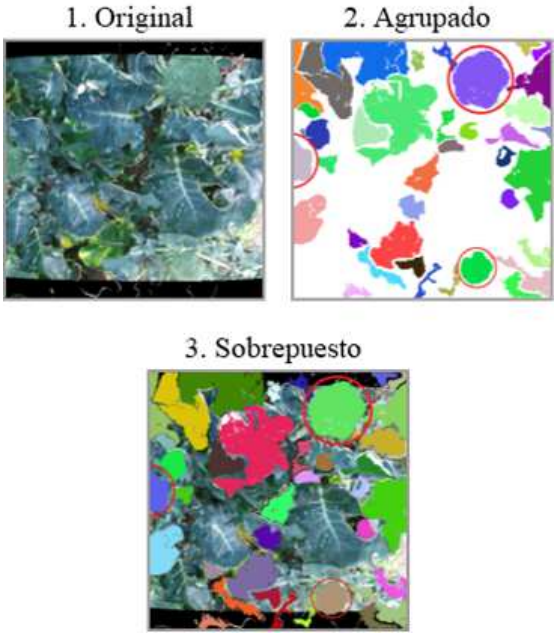


Figura 3. Identificación de grupos en una nube de puntos. (1) Vista frontal de la imagen original, (2) Grupos extraídos con cada brócoli dentro de un círculo, (3) Grupos sobrepuestos en la imagen original.

Etapa de estimación de características

En esta etapa se determinan las propiedades de interés de un grupo. Se considerarán dos formas: mediante el cálculo del centroide (ecuación 1) que se utiliza para representar el punto central del grupo, y mediante el cálculo del histograma utilizando el descriptor VFH (*Viewpoint Feature Histogram*). Éste último se construye usando las normales de los puntos del grupo y la comparación de ángulos de inclinación entre las normales [9].

$$(x, y, z) = \left(\frac{1}{n}\right) \sum_{i=0}^{n} (x_i, y_i, z_i) \quad (1)$$

*https://lcas.lincoln.ac.uk/nextcloud/shared/agritech-datasets/broccoli/broccoli_datasets.html

Donde: (x, y, z) representa el promedio de todos los puntos de un grupo como un punto en el espacio tridimensional. La variable n es el número total de puntos que tiene el grupo, por lo que (x_i,y_i,z_i) es un punto dentro del grupo en la posición i.

Etapa de anotación manual

La anotación de datos es un proceso que generalmente se realiza de forma manual, lo que implica que una persona utiliza su criterio para seleccionar los datos relevantes. En el caso específico del brócoli, el objetivo es que una persona pueda visualizar una nube de puntos mediante una interfaz interactiva y, así, identificar y seleccionar un grupo que represente una cabeza del brócoli.

La anotación se lleva realiza en la misma interfaz, donde se escogen los puntos que pertenecen a un brócoli. Si alguno de los puntos seleccionados forma parte de un grupo que ya fue extraído previamente, los demás puntos de ese grupo se seleccionan automáticamente para asegurar que todos los puntos relevantes sean anotados.

Etapa de anotación por centroide

La anotación por centroide tiene como objetivo la identificación y etiquetado automático de grupos extraídos que puedan corresponderse a un brócoli. Se requiere de grupos extraídos y un conjunto de datos de referencia (grupos previamente anotados).

En cada uno de estos grupos, se aplica el proceso de estimación de características, centrado en el cálculo de los centroides. Posteriormente, se calculan las distancias euclidianas entre los centroides anotados y los centroides extraídos (ecuación 2).

$$d = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2} \quad (2)$$

Con la definición de un umbral de cercanía se determina si los grupoes extraídos son lo suficientemente cercanos a los grupoes anotados para entonces realizar la notación (ver Figura 4).

Etapa de anotación por histograma

La anotación por histograma busca identificar y etiquetar de forma automática grupos extraídos que puedan corresponder a un brócoli. Para ello, se requiere de grupos extraídos y un conjunto de datos de referencia (grupos previamente anotados).

Una vez calculados los histogramas, se utiliza el coeficiente de correlación de Pearson, para encontrar la similitud entre dos histogramas y determinar qué grupos se anotarán como brócoli (ver Figura 4).

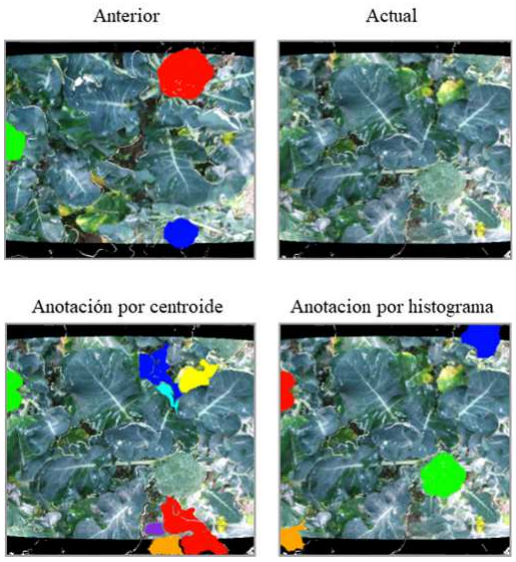


Figura 4. Anotación automática por estimación de centroides e histogramas. Fuente: Elaboración propia.

En la Figura 4, se muestran los grupos anotados en diferentes colores sobre una nube de puntos. La imagen etiquetada como 'Actual' muestra otra nube de puntos adyacente a la que se ve en la imagen 'Anterior'. En la imagen 'Actual', se aplica el proceso de agrupamiento para después aplicar el proceso de anotación por centroide y en otra prueba se cambia a anotación por histograma.

LargeExperimentación y resultados

La experimentación consideró el uso de 299 muestras previamente etiquetadas para asegurar la precisión en los resultados obtenidos. Este conjunto es conocido como *ground truth*. (ver Figura 5).

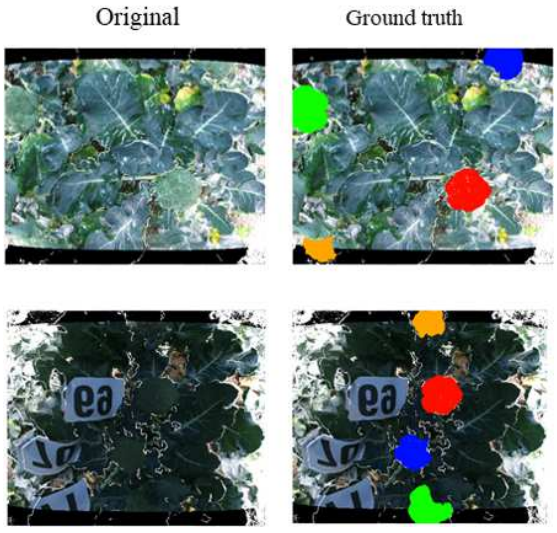


Figura 5. Muestras de campos sin ground truth y con ground truth. Fuente: Elaboración propia.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

La idea es solo usar una muestra de referencia para los procesos de anotación por centroide e histograma (Figura 6).

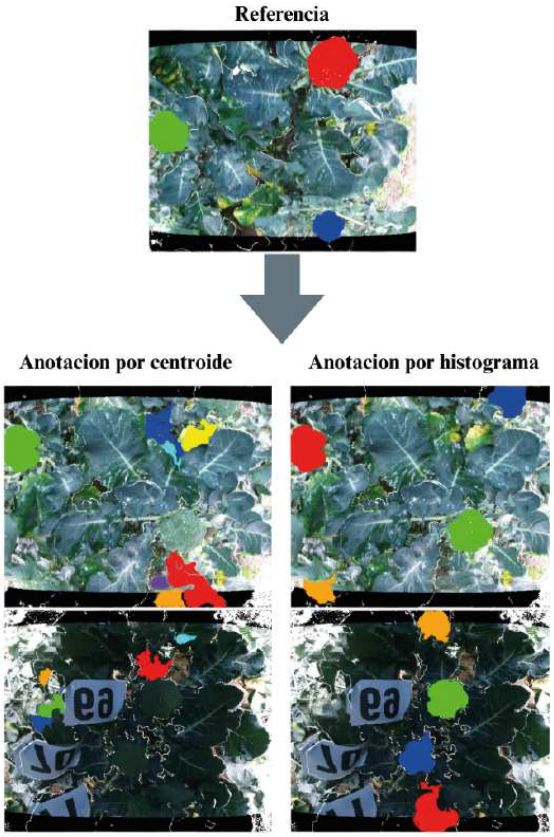


Figura 6. Anotación de brócoli comparando la anotación por centroide y la anotación por histograma usando solo una muestra de referencia. Fuente: Elaboración Propia

Con las 299 muestras se experimentó con la anotación por histograma y se compararon los resultados con el *ground truth*, calculando así la efectividad del método en un 77 % (ver Tabla 1).

Tabla 1. Resultados con la experimentación de anotación por histograma.

Método utilizado		**Etiquetados**
Ground truth	**histograma**	**correctamente**
1058 grupos	850 grupos	819 grupos

Conclusiones

forma automática cabezas de brócoli utilizando imágenes RGB-D. El método considera la obtención de grupos que serán utilizados como guía en el proceso de anotación manual. Con esto se busca tener una selección más rápida y precisa de las cabezas de brócoli que serán utilizadas en el proceso de estimación de características. Por último, estas estimaciones son usadas para los procesos de anotación por centroide y anotación por histograma.

Los resultados obtenidos reportan un 77 % de efectividad en el etiquetado automático de brócoli, lo que, en el proceso de cultivo permite disminuir el trabajo arduo que implica la anotación de datos, para después revisar los datos que se anotaron automáticamente y que una persona los pueda considerar válidos o que pueda seguir completando la anotación usando el proceso de anotación manual.

En un futuro se proponer mejoras en el proceso de agrupamiento para que se logre discriminar elementos que no son de interés (hojas, tallos o suelo), mejorando así la precisión y evitando la pérdida de los datos o el etiquetado de estos.

Otra dirección posible de estudio es ampliar el proceso de estimación de características y, consecuentemente, los procesos de anotación.✷

REFERENCIAS

1. Erkan, M. y Dogan, A. (2019) Harvesting of Horticultural Commodities,» de Postharvest Technology of Perishable Horticultural Commodities. *Woodhead Publishing*, 129-159.

2. Telus International. Five common data annotation challenges and how to solve them. Accedido el 4 de Noviembre de 2022. Disponible en: `https://www.telusinternational.com/insights/ai-data/article/data-annotation-challenges`.

3. Li, L., Wang, R. y Zhang, X. (2021). A Tutorial Review on Point Cloud Registrations: Principle, Classification, Comparison, and Technology Challenges. *Mathematical Problems in Engineering*, 2021, 32.

4. Blok, P., van Henten, E., van Evert, F. y Kootstra, G. (2021). Image-based size estimation of broccoli heads under varying degrees of occlusion. *Biosystems Engineering*, 208, 2013-233.

5. Blok, P., van Evert, F., Tielen, A, van Henten, E. y Kootstra, G. (2021). The effect of data augmentation and network simplification on the image-based detection of broccoli heads with Mask R-CNN. *Journal of Field Robotics*, 38, 85-104.

6. Kusumam, K., Krajník, T., Pearson, S., Duckett, T. y Cielniak, G. (2017). 3D-vision based detection, localization, and sizing of broccoli heads in the field. *Journal of Field Robotics*, 34, 1505-1518.

7. Louedec, J., Montes, H., Duckett, T. y Cielniak, G. (2020). Segmentation and detection from organised 3D point clouds: a case study in broccoli head detection. En *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 285-293.

8. Montes, H, Le Louedec, J., Cielniak, G. y Duckett, T. (2020). Real-time detection of broccoli crops in 3D point clouds for autonomous robotic harvesting. En *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 10483-10488.

9. Rusu, R., Bradski, G., Thibaux, R. y Hsu, J. (2010). Fast 3D recognition and pose using the Viewpoint Feature Histogram. *IEEE*.

10. Kootstra, G., Wang, X., Blok, P., Hemming, J. y van Henten, E. (2021). Selective Harvesting Robotics: Current Research, Trends, and Future Directions. *Current Robotics Reports*, 2, 95-104.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

SOBRE LOS AUTORES



Ricardo Ángel Álvarez Macedo. es estudiante de Ingeniería en computación participante en proyectos de investigación relacionados a tratamiento de imágenes digitales, ciencia y analítica de datos aplicada.



José Luis López Díaz. es estudiante de Ingeniería en computación participante en proyectos de investigación relacionados a tratamiento de imágenes digitales, ciencia y analítica de datos aplicada.



Héctor Alejandro Montes Benegas. es Doctor en Ciencias Computacionales por la Universidad de Lincoln, UK. Cuenta con varios años de experiencia en empresas del sector público y privado como asesor externo en desarrollo de software, capacitación de personal y asesoría en sistemas de computo. Es Profesor de Tiempo Completo en la Facultad de Ingeniería en la UAEMex. Sus intereses de investigación incluyen algoritmos de Computo Evolutivo aplicados a problemas de optimización combinatoria y Percepción Robótica que involucra la adquisición, procesamiento, análisis e interpretación de los datos que producen para tareas de robótica móvil y aprendizaje máquina. Ha dirigido y codirigido tesis de Licenciatura y de Maestría.



Rosa María Valdovinos Rosas. es Doctora en ciencias computacionales, miembro del SNI nivel II. Con productos que inciden en varios PRONACES: proyectos de investigación, artículos en revistas indizadas y congresos, capítulos de libro, libros y 1 licencia de patente. Ha formado estudiantes de nivel licenciatura, Maestría y Doctorado. Colabora en la organización de eventos académicos para la divulgación de la ciencia, acciones orientadas a niñas en la computación y vocaciones tempranas. Con más de 1000 citas y un índice H14, el *International AD Scientific index 2023* la considera una las 10,000 científicas más influyentes a nivel Nacional.



José Raymundo Marcial Romero. es Doctor en Ciencias de la Computación por The University of Birmingham, UK. Profesor de tiempo completo en la Facultad de Ingeniería de la UAEMex. Miembro del SNI nivel 1. Miembro de la academia Mexicana de Ciencias de la Computación, con aportaciones en las áreas de teoría de grafos, semántica de lenguajes de programación y la lógica computacional. De acuerdo con Google Scholar, ha publicado más de 90 artículos de investigación para revista y capítulos de libro. Ha impulsado proyectos estratégicos para la Universidad en la que labora desde la Secretaría de Planeación y la Secretaría de Docencia.



Imagen tomada de:
https://cvg.cit.tum.de/research/rgb-d_sensors_kinect.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Generación de Datos Sintéticos Mediante Redes Generativas Adversarias para Mejorar la Detección de Diabetes: Validación de Modelos Predictivos Basados en Aprendizaje Automático

Antonio García-Domínguez, Carlos E. Galván-Tejada y Rafael Magallanes-Quintanar

Introducción

La diabetes es una enfermedad crónica que afecta a millones de personas en todo el mundo y representa una carga significativa para la salud pública [1]. La detección temprana y precisa de la diabetes es fundamental para un tratamiento efectivo y el control de la enfermedad, lo que puede ayudar a prevenir o retrasar las complicaciones asociadas. En los últimos años, los avances en técnicas de aprendizaje automático y algoritmos de clasificación han mejorado la detección y diagnóstico de la diabetes. Utilizando datos clínicos y paraclínicos, se desarrollan modelos de predicción que identifican patrones y señales tempranas, brindando apoyo a la toma de decisiones clínicas y a estrategias preventivas.

Uno de los desafíos en la predicción de la diabetes es la disponibilidad de grandes conjuntos de datos representativos. Recopilar datos clínicos y paraclínicos a gran escala es costoso y requiere colaboración entre instituciones médicas y participación de una gran cantidad de pacientes. Obtener datos longitudinales a lo largo del tiempo es aún más desafiante. Además de la disponibilidad limitada de datos, la heterogeneidad de los datos recopilados es otro desafío. Varían en formato, estructura y calidad, lo que dificulta su integración y análisis efectivo. Esto afecta la calidad y confiabilidad de los modelos de predicción. Se necesitan enfoques innovadores para superar estas limitaciones y aprovechar al máximo los conjuntos de datos existentes.

En este contexto, la generación de datos sintéticos surge como una solución prometedora para superar esta limitación. Las Redes Generativas Adversarias (RGAs) han demostrado ser eficaces en la generación de datos sintéticos de alta calidad. Estas redes consisten en una red generadora y una red discriminadora que compiten entre sí, mejorando progresivamente la calidad de los datos generados a medida que se entrenan juntas. La generación de datos sintéticos mediante RGAs ofrece una opción para abordar la limitación de conjuntos de datos insuficientes en el campo de la predicción de la diabetes. Este enfoque innovador tiene el potencial de mejorar la precisión y la generalización de los modelos de predicción, lo que a su vez puede tener un impacto significativo en la detección temprana y el manejo de la diabetes.

En este artículo, se presenta la generación de datos sintéticos mediante RGAs para un conjunto de datos de diabetes utilizado para evaluar modelos de predicción desarrollados previamente. El objetivo principal es mejorar la precisión y la capacidad de generalización de los modelos existentes al expandir el conjunto de datos original a través de la generación de muestras sintéticas. Al aplicar este enfoque, se pretende explorar un espacio de datos más amplio y diverso, lo que permitirá descubrir patrones ocultos y mejorar la robustez de los modelos de predicción. Además, esta técnica proporciona una oportunidad para validar y evaluar la efectividad de los modelos en un contexto más amplio y realista.

Generación de Datos Sintéticos en Investigación Biomédica

La generación de datos sintéticos ha sido ampliamente utilizada en diversas áreas de investigación, como la genómica, la imagenología médica, la epidemiología y el estudio de enfermedades crónicas como la diabetes, con el objetivo de abordar limitaciones relacionadas con la disponibilidad, heterogeneidad y confidencialidad de los conjuntos de datos [2-5]. En cada una de estas disciplinas, la generación de datos sintéticos ha permitido superar desafíos específicos, como la escasez de muestras genéticas, la falta de imágenes médicas anotadas, las restricciones éticas en el uso de datos sensibles y la necesidad de datos más amplios y representativos. Esta técnica ha demostrado ser una herramienta valiosa para mejorar la calidad de los modelos predictivos, la detección temprana de enfermedades, la estratificación de riesgos y la generación de intervenciones personalizadas, impulsando así el avance de la investigación biomédica y la salud en general.

Las RGAs mejoran el rendimiento y la adaptabilidad en el aprendizaje automático, con diversidad y autenticidad de datos.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

En el contexto específico de la diabetes, la generación de datos sintéticos puede desempeñar un papel fundamental en la mejora de la detección temprana de la enfermedad y en la validación de modelos predictivos. Al ampliar y enriquecer el conjunto de datos existente mediante la generación de datos sintéticos, los investigadores pueden mejorar la capacidad de los modelos de aprendizaje automático para identificar patrones y factores de riesgo asociados con la diabetes, lo que contribuye a un mejor manejo y prevención de esta enfermedad crónica [6].

RGAs: Herramientas para la Generación de Datos Sintéticos

Las RGAs son un tipo de modelo de aprendizaje automático que ha encontrado amplias aplicaciones en diversos campos, incluyendo la investigación biomédica. Estas redes han demostrado ser una herramienta prometedora en la generación de datos sintéticos que se asemejan a los datos reales. Su funcionamiento se basa en la interacción entre dos componentes principales: el generador y el discriminador.

El generador en una RGA es una red neuronal que tiene como objetivo sintetizar datos auténticos a partir de un espacio de ruido latente. Utilizando una serie de capas y conexiones, el generador transforma el ruido de entrada en muestras de datos que se asemejan a las muestras auténticas. Su función principal es aprender a generar datos sintéticos que engañen al discriminador, buscando maximizar la similitud con los datos auténticos.

Por otro lado, el discriminador es otra red neuronal en la RGA cuyo propósito es distinguir entre las muestras auténticas y las generadas por el generador. Actúa como un "juez" que evalúa la autenticidad de los datos, asignando una probabilidad de ser auténtico o falso a cada muestra. Su función es aprender a clasificar de manera precisa y discernir las diferencias sutiles entre las muestras reales y las generadas.

Ambos componentes se entrenan de forma adversaria, lo que significa que se retroalimentan mutuamente. El generador busca generar muestras cada vez más realistas para engañar al discriminador, mientras que el discriminador se entrena para ser cada vez más preciso en la distinción entre lo real y lo sintético. Este proceso iterativo de competencia entre el generador y el discriminador impulsa el aprendizaje de la RGA y permite la generación de datos sintéticos de alta calidad.

En conjunto, el generador y el discriminador trabajan en colaboración para mejorar la capacidad de la RGA para generar datos sintéticos que sean indistinguibles de los datos reales. Esta dinámica de adversidad y competencia es clave en el funcionamiento de las RGAs y ha demostrado ser altamente efectiva en la generación de datos sintéticos en una variedad de campos de investigación [7]. La arquitectura de una RGA se muestra en la Figura 1.

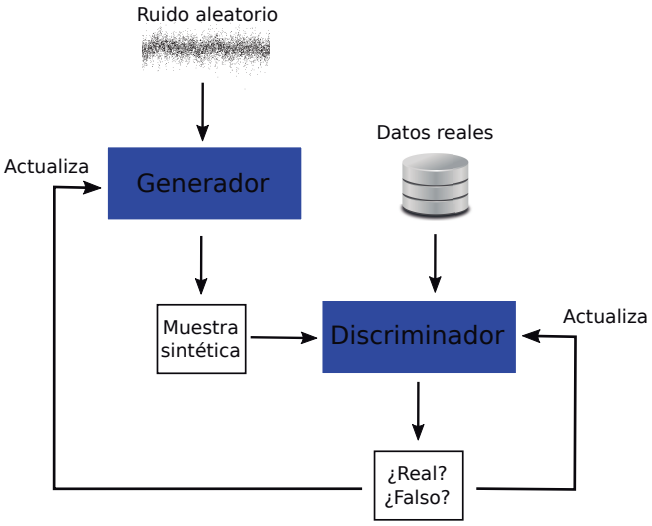


Figura 1. AArquitecrura de una RGA.

Dentro de un contexto más amplio, en la generación de datos sintéticos, las RGAs han dejado su huella en campos como la visión por computadora y la producción de contenido multimedia [8]. Un ejemplo extraordinario de su destreza se encuentra en su aplicación para la creación de retratos de individuos inexistentes en la realidad. Investigaciones recientes han empleado RGAs para generar imágenes de alta resolución de rostros humanos que resultan virtualmente indistinguibles de fotografías auténticas [9]. Estos ejemplos ilustran la formidable capacidad de las RGAs en la producción de imágenes realistas, un potencial que podría extenderse a la ampliación de conjuntos de datos en el ámbito de la diabetes y otras esferas de la salud.

Ampliación del Conjunto de Datos para Detección de Diabetes

El conjunto de datos utilizado en este trabajo consta de 1019 muestras y es el mismo que fue empleado por García et al. en su estudio anterior sobre la detección de la diabetes mediante algoritmos de aprendizaje automático [10], y se detalla en la Tabla 1. En su investigación, García et al. llevaron a cabo un proceso de selección de características, destacando la ventaja de esta técnica para identificar las características más relevantes y significativas para la detección de la enfermedad. Partiendo de un conjunto inicial de 19 características, lograron identificar un subconjunto crucial de 5 características, que se describen en la Tabla 2, y que resultaron ser las más representativas para la generación de modelos de clasificación con un conjunto de datos reducido. Es precisamente este conjunto de datos, que consta de las 5 características seleccionadas, el que se ha empleado en el presente trabajo

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

como base para aplicar el método de generación de datos sintéticos mediante RGAs. El enfoque principal de este trabajo se centra en la generación de datos sintéticos para ampliar el conjunto de datos existente y permitir una comparación con modelos de clasificación previamente validados. La descripción general del conjunto de datos junto con las 5 características seleccionadas proporcionan una base suficiente para la comprensión de este enfoque.

Tabla 1. Descripción del Conjunto de Datos

Característica	Valor
Total de pacientes	1019
Nacionalidad	Mexicana
Pacientes femeninos	502
Pacientes masculinos	517
Pacientes no diabéticos (control)	499
Pacientes diabéticos (casos)	520
Edad mínima	35
Edad máxima	65
Tiempo con diabetes	+5 años
Otras enfermedades	No

Tabla 2. Características identificadas como más relevantes mediante el proceso de selección de características

Características seleccionadas
Educación
Glucosa
Edad
Perímetro abdominal
Glucosa en sangre (concentración molecular)

La ampliación del conjunto de datos para la detección de diabetes mediante la generación de datos sintéticos utilizando RGAs tiene como objetivo enriquecer y diversificar aún más el conjunto de datos existente. Esto permitirá explorar un espacio de datos más amplio y mejorar la capacidad de los modelos predictivos para identificar patrones y factores de riesgo asociados con la diabetes.

Es importante aclarar que la ampliación del conjunto de datos se refiere exclusivamente al incremento en la cantidad de muestras disponibles, no al aumento de características. El proceso de selección de características previo tuvo como objetivo reducir el número de características a un conjunto relevante. Por lo tanto, la ampliación del conjunto de datos se enfoca en obtener más muestras con estas características seleccionadas, lo que resulta en un conjunto de datos más representativo y diverso para el desarrollo y validación de los modelos predictivos. Esta distinción es crucial para comprender el enfoque de ampliación del conjunto de datos y su impacto en la mejora de la detección de la diabetes.

La determinación del nivel de ampliación del conjunto de datos mediante RGAs se basa en múltiples consideraciones, incluyendo la complejidad de los datos, la disponibilidad de recursos computacionales y el balance entre la calidad y cantidad de muestras. Específicamente para el conjunto de datos inicial de 1019 muestras, resulta fundamental evaluar el impacto que la ampliación tendrá en el desempeño de los modelos predictivos.

Para garantizar una expansión cuidadosa del conjunto de datos y evitar incrementos excesivos que puedan resultar en redundancias o sesgos en los datos generados, se ha realizado una serie de evaluaciones considerando diferentes niveles de aumento, específicamente, del 20 %, 30 % y 40 %. Tras analizar exhaustivamente los resultados de los modelos de clasificación en estas condiciones, se ha observado que el incremento del 30 % arroja los mejores resultados. Este porcentaje de incremento agregará 305 muestras adicionales al conjunto de datos. Esta estrategia de ampliación moderada permite introducir variabilidad en el conjunto de datos sin comprometer su representatividad ni crear un desequilibrio excesivo entre las clases. Por lo tanto, en este estudio, se propone un incremento del 30 % en el tamaño del conjunto de datos como la elección más adecuada.

Evaluación de Modelos Predictivos con el Conjunto de Datos Ampliado

En el trabajo desarrollado previamente [10] se realizó la evaluación de múltiples modelos de clasificación utilizando el conjunto de datos de diabetes y los siguientes algoritmos de aprendizaje automático: Support Vector Machines (SVM), Random Forests (RF), k-Nearest Neighbors (kNN), Gradient Boosting (GB), Extra Trees (ET) y Naive Bayes (NB). Mediante la aplicación de algoritmos genéticos, en ese trabajo se llevó a cabo un proceso de selección de características, lo cual permitió obtener un subconjunto de 5 características altamente representativas. Los resultados obtenidos para estos modelos se presentan en la Tabla 3, donde se muestra el desempeño en diversas métricas de evaluación, como el área bajo la curva (AUC), la especificidad, la sensibilidad, la exactitud (accuracy), la puntuación F1 y la precisión.

Tabla 3. Desempeño de los modelos de clasificación con el conjunto de datos original de 1019 muestras en el estudio previo [10]

Métrica	SVM	RF	kNN	GB	ET	NB
AUC	0.97	0.97	0.96	0.97	0.97	0.98
Especificidad	0.92	0.94	0.91	0.94	0.94	0.91
Sensitividad	0.97	0.97	0.94	0.95	0.96	0.95
Exactitud	0.94	0.95	0.93	0.94	0.95	0.93
F1	0.94	0.95	0.92	0.95	0.95	0.93
Precisión	0.97	0.97	0.94	0.95	0.96	0.96

Los resultados obtenidos en la investigación previa, presentados en la Tabla 3, han sentado las bases para el presente trabajo. Ahora, la investigación se enfoca en

una nueva fase de evaluación, donde se ha ampliado el conjunto de datos incluyendo tanto muestras reales como sintéticas. Esto permitirá examinar de manera más completa el impacto de la generación de datos sintéticos en el rendimiento de los modelos y obtener una visión más sólida sobre su capacidad de clasificación en el contexto de la diabetes.

Experimentos y Resultados

En la primera fase de experimentación de este estudio, se llevó a cabo la creación y configuración de una RGA para la generación de los datos sintéticos. En la Tabla 4 se detalla la configuración específica de la RGA utilizada. El generador fue configurado considerando parámetros como la dimensión latente, el número y tipo de capas, así como el inicializador del kernel. Por otro lado, el discriminador se ajustó con respecto a las capas, el inicializador del kernel, la función de pérdida y el optimizador. Estas configuraciones y parámetros desempeñan un papel crucial en la capacidad de la RGA para generar datos sintéticos que sean realistas y de alta calidad.

Tabla 4. Configuración de la RGA, el generador y el discriminador

Componente	Configuración
Generador	Dimensión latente: 10 Capas: 15 (ReLU), 30 (ReLU), 6 (Linear) Inicializador del kernel: He Uniforme
Discriminador	Capas: 25 (ReLU), 50 (ReLU), 1 (Sigmoid) Inicializador del kernel: He Uniforme Función de pérdida: Binary Crossentropy Optimizador: Adam
RGA	Pesos del discriminador no entrenables Función de pérdida: Binary Crossentropy Optimizador: Adam
Entrenamiento	Dimensión latente: 10 Épocas: 10000 Tamaño del lote: 128 Evaluación cada: 200 épocas

Tras aplicar la RGA al conjunto de datos original, se generó un conjunto adicional de datos sintéticos que representa aproximadamente el 30 % del tamaño inicial. Estas muestras sintéticas fueron creadas mediante el generador de la RGA utilizando una dimensión latente de 10. Posteriormente, se concatenaron con el conjunto de datos original, resultando en un conjunto de datos ampliado que incluye tanto las muestras reales como las sintéticas generadas por la RGA. La Tabla 5 resume la cantidad de muestras en el conjuto de datos antes y después de la ampliación.

Tabla 5. Resumen del número de muestras en el conjunto de datos antes y después de la ampliación con datos sintéticos

Conjunto de Datos	Número de muestras
Original	1019
Ampliado	1325

El conjunto de datos original constaba de 1019 muestras, mientras que el conjunto de datos ampliado, que incluye las muestras sintéticas generadas por la RGA, tiene un total de 1325 muestras. Esta ampliación del conjunto de datos permite evaluar el impacto de los datos sintéticos en el rendimiento de los modelos predictivos utilizados en el estudio.

En la segunda fase de experimentación, se evaluaron los modelos de clasificación desarrollados en el estudio previo, ahora utilizando el conjunto de datos ampliado que incluye tanto los datos reales como los datos sintéticos generados. Los modelos fueron evaluados utilizando las mismas métricas de rendimiento utilizadas anteriormente, lo que permitió comparar directamente su desempeño con el nuevo conjunto de datos, y los resultados se presentan en la Tabla 6.

Tabla 6. Desempeño de los modelos de clasificación con el conjunto de datos ampliado ampliado al 30 % mediante la RGA

Métrica	SVM	RF	kNN	GB	ET	NB
AUC	0.94	0.95	0.94	0.95	0.96	0.90
Especificidad	0.95	0.96	0.93	0.96	0.96	0.96
Sensitividad	0.94	0.95	0.94	0.95	0.95	0.85
Exactitud	0.94	0.95	0.94	0.95	0.96	0.90
F1	0.94	0.95	0.93	0.95	0.96	0.90
Precisión	0.94	0.96	0.93	0.95	0.96	0.95

En las Tablas 7 y 8 se presenta el desempeño de los modelos de clasificación aplicados al conjunto de datos ampliado, generado mediante la RGA, con incrementos del 20 % y 40 %, respectivamente. En estas Tablas, es evidente que el desempeño de los modelos con estos niveles de incremento es inferior en comparación con el conjunto de datos que experimentó un aumento del 30 %. Las métricas de rendimiento muestran que el incremento del 30 % es el que produce los resultados más favorables, lo que respalda de manera sólida nuestra elección de este porcentaje como el más adecuado para nuestro estudio. Estos hallazgos destacan la importancia de la selección cuidadosa del nivel de incremento en la generación de datos sintéticos para garantizar el rendimiento óptimo de los modelos de clasificación en la tarea de detección de diabetes.

Tabla 7. Desempeño de los modelos de clasificación con el conjunto de datos ampliado al 20 % mediante la RGA

Métrica	SVM	RF	kNN	GB	ET	NB
AUC	0.91	0.95	0.91	0.93	0.94	0.86
Especificidad	0.92	0.95	0.90	0.92	0.93	0.92
Sensitividad	0.89	0.95	0.91	0.94	0.95	0.80
Exactitud	0.90	0.95	0.91	0.93	0.94	0.86
F1	0.90	0.95	0.91	0.93	0.94	0.85
Precisión	0.92	0.95	0.90	0.92	0.93	0.91

Tabla 8. Desempeño de los modelos de clasificación con el conjunto de datos ampliado al 40 % mediante la RGA

Métrica	SVM	RF	kNN	GB	ET	NB
AUC	0.79	0.94	0.85	0.93	0.95	0.56
Especificidad	0.85	0.94	0.83	0.93	0.95	0.39
Sensitividad	0.74	0.94	0.87	0.94	0.95	0.73
Exactitud	0.79	0.94	0.85	0.93	0.95	0.58
F1	0.80	0.94	0.87	0.94	0.96	0.66
Precisión	0.86	0.95	0.87	0.94	0.96	0.61

Discusión y Conclusiones

La generación de datos sintéticos mediante RGAs en la investigación de la diabetes tiene implicaciones y beneficios significativos. Al superar las limitaciones de acceso y privacidad de los conjuntos de datos reales, se facilita la colaboración y el intercambio de información entre investigadores. Esto promueve el avance científico en el campo de la diabetes al permitir estudios y análisis sin comprometer la confidencialidad de los datos reales.

Además, la generación de datos sintéticos brinda la oportunidad de explorar escenarios y condiciones difíciles de replicar en datos reales. Al tener control total sobre la generación de datos, se pueden simular situaciones extremas y evaluar el impacto de variables específicas en los modelos de predicción y clasificación. Esto ayuda a comprender los límites y alcances de los modelos, identificar áreas de mejora y optimización, y seleccionar los enfoques más efectivos para el diagnóstico y tratamiento de la diabetes.

La generación de datos sintéticos mediante RGAs en la investigación de la diabetes ha demostrado un rendimiento positivo en general. Los resultados presentados en la Tabla 6, comparados con los de la Tabla 3, respaldan de manera alentadora la efectividad de las RGAs en la generación de datos sintéticos para mejorar los modelos de clasificación en el conjunto de datos de diabetes.

Los modelos de clasificación evaluados con el conjunto de datos ampliado presentaron métricas comparables y, en muchos casos, incluso mejoradas en comparación con los resultados obtenidos con el conjunto de datos original. Esto indica que la incorporación de datos sintéticos generados por RGAs ha logrado enriquecer el conjunto de datos y mejorar la capacidad de los modelos para detectar patrones y realizar predicciones precisas.

Al comparar los resultados obtenidos con el conjunto de datos original y el conjunto de datos ampliado mediante la RGA, se observa que, si bien algunas métricas como AUC mostraron una ligera disminución en los nuevos resultados, otras métricas clave experimentaron mejoras notables. La especificidad mejoró en la mayoría de los modelos, alcanzando valores entre 0.93 y 0.96 en el conjunto de datos ampliado, en comparación con 0.91–0.94 en el conjunto de datos original. Además, la precisión se mantuvo alta en los nuevos resultados, con valores de 0.93–0.96, lo que indica una consistencia en la capacidad de los modelos para clasificar correctamente los casos positivos. Estas mejoras en la especificidad y la precisión son especialmente valiosas en el contexto de la detección de la diabetes, ya que reducirían los falsos positivos y, por lo tanto, ayudarían a evitar diagnósticos incorrectos. A pesar de las ligeras variaciones en otras métricas, la estabilidad general del rendimiento de los modelos en el conjunto de datos ampliado sugiere que la generación de datos sintéticos mediante RGAs no solo no perjudicó el rendimiento, sino que además contribuyó a una mejora en aspectos clave de la clasificación.

La inclusión de múltiples métricas en la tabla de resultados se justifica debido a la necesidad de evaluar el rendimiento de los modelos desde diversas perspectivas. Cada métrica proporciona información única sobre la calidad de los modelos y su capacidad para realizar predicciones precisas. Por ejemplo, el AUC (Área bajo la Curva ROC) mide la habilidad del modelo para discriminar entre clases, donde un valor cercano a 1 indica un mejor rendimiento en este aspecto. La especificidad se refiere a la capacidad del modelo para identificar correctamente a los individuos sanos, mientras que la sensibilidad evalúa su capacidad para detectar a los enfermos. La precisión indica cuántas de las predicciones positivas del modelo son realmente correctas. Al presentar un conjunto completo de métricas, se facilita la comprensión tanto para especialistas como para el público no especializado, permitiendo una evaluación exhaustiva y precisa del desempeño de los modelos.

Los resultados obtenidos respaldan firmemente la utilización de RGAs para la generación de datos sintéticos en el conjunto de datos de diabetes. Estos hallazgos sugieren que la incorporación de datos sintéticos puede mejorar significativamente la capacidad de los modelos de clasificación para predecir y diagnosticar la diabetes con precisión. Este enfoque ofrece oportunidades prometedoras para el avance de la investigación en el campo de la diabetes y puede contribuir a un mejor manejo de la enfermedad en la práctica clínica. Los resultados presentados en este estudio son prometedores, ya que demuestran que la generación de datos sintéticos mediante RGAs tiene un impacto positivo en el rendimiento de los modelos de clasificación en el contexto de la diabetes. Sin embargo, se reconoce que, para una validación más

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

completa y una comprensión más profunda de las ventajas de esta técnica, se requerirá una evaluación adicional con conjuntos de datos más amplios y diversos. Futuros trabajos podrían considerar la aplicación de RGAs en un entorno clínico real con datos de pacientes y un espectro más amplio de características clínicas. Esto permitiría una validación más sólida de la efectividad de los modelos en situaciones del mundo real y la generación de datos sintéticos que reflejen aún más auténticamente la diversidad de casos clínicos. Además, la inclusión de más métricas de evaluación específicas para el diagnóstico de la diabetes, como la precisión en la identificación de subtipos de diabetes o la predicción de complicaciones específicas, podría proporcionar una visión más completa de las capacidades de los modelos. Estos pasos adicionales fortalecerían aún más el argumento de que la generación de datos sintéticos mediante RGAs es una herramienta valiosa para la investigación y el tratamiento de la diabetes.✷

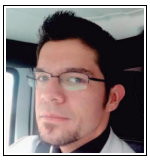
REFERENCIAS

1. Organización Mundial de la Salud. (2021). Diabetes. Recuperado el 5 de julio de 2023, de `https://www.who.int/es/news-room/fact-sheets/detail/diabetes`.
2. Xie, C., Zheng, H., Guan, L., Liu, C. y Xue, Y. (2020). Synthetic data generation for privacy-preserving genomic studies. *Bioinformatics*, 36(18), 4682-4688.
3. Heo, G. E., Ma, J., Kim, K. y Lee, J. (2021). SynGAN: Synthetic data generation using GAN with regularization. *BMC Bioinformatics*, 22(1), 1-15.
4. Sathya, S. R., Arunkumar, N. y Soman, K. P. (2022). DCGAN-generated synthetic medical images for anomaly detection using domain adaptation. *IEEE Journal of Biomedical and Health Informatics*, 26(8), 2382-2392.
5. Aydemir, S., Günel, K. y Erdoğmuş, D. (2023). Generating Synthetic COVID-19 Data with GANs to Improve Risk Prediction Models. *International Journal of Environmental Research and Public Health*, 20(3), 1327.
6. Li, H., Zhang, B. y Tang, S. (2022). Synthetic Data Generation for Predictive Modeling of Diabetes and Its Complications. *Frontiers in Genetics*, 13, 872.
7. Brock, A., et al. (2022). High-Resolution Image Synthesis with GANs Using Adaptive Instance Normalization. I*EEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1), 130-145.
8. Wang, X., Yu, K., Wu, C., Dong, C., Tang, X. y Change Loy, C. (2019). Pairedcyclegan: Asymmetric style transfer for applying and removing makeup. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*.
9. Kammoun, A., Slama, R., Tabia, H., Ouni, T. y Abid, M. (2022). Generative Adversarial Networks for face generation: A survey. *ACM Computing Surveys*, 55(5), 1-37.
10. García-Domínguez, A., Galván-Tejada, C. E., Magallanes-Quintanar, R., Gamboa-Rosales, H., Curiel, I. G., Peralta-Romero, J., Cruz, M. y others. (2023). Diabetes Detection Models in Mexican Patients by Combining Machine Learning Algorithms and Feature Selection Techniques for Clinical and Paraclinical Attributes: A Comparative Evaluation. *Journal of Diabetes Research*, 2023. Hindawi.

SOBRE LOS AUTORES



Antonio García-Domínguez es Doctor en Ciencias de la Ingeniería por la Universidad Autónoma de Zacatecas y Maestro en Ingeniería de la Computación por la Universidad Nacional Autónoma de México. Sus áreas de interés son la Inteligencia Artificial, la Inteligencia Ambiental, las Ciudades Inteligentes y el aprendizaje automático. Actualmente pertenece al Sistema Nacional de Investigadores en nivel Candidato.



Carlos E. Galván-Tejada obtuvo el título de Ingeniero en Ciencias de la Computación y la Maestría en Ingeniería por la Universidad Autónoma de Zacatecas. Doctor en Tecnologías de la Información y Comunicación con especialidad en Inteligencia Ambiental en el Tecnológico de Monterrey, campus Monterrey. Sus intereses de investigación incluyen la Inteligencia Ambiental, el Procesamiento de Señales, la Investigación Contextual, la Computación Contextual, la Bioinformática y el Desarrollo de Juegos. Actualmente pertenece al Sistema Nacional de Investigadores (SNI 2) en el Área III: Medicina y ciencias de la salud.



Rafael Magallanes-Quintanar es Doctor en Ciencias Pecuarias y Maestro en Ciencias en Riego y Drenaje. Es miembro del Sistema Nacional de Investigadores e Investigadoras en nivel I. Se desempeña como profesor-investigador de tiempo completo en la Universidad Autónoma de Zacatecas en la Unidad Académica de Ingeniería Eléctrica en la carrera de Ingeniería en Computación. Sus áreas de interés son los sistemas complejos y el cambio climático.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

La Evaluación de Habilidades en Cirujanos Laparoscópicos: La Inteligencia Artificial al Rescate

Naidelyn Linares-Guzmán, Oscar-Eduardo Franco-Juan, Juan Hereiva-Osorio, Rigoberto Martínez-Mendez, Rosa-María Valdovinos-Rosas y Daniel Lorias-Espinoza

Introducción

Imaginemos un futuro en el que la habilidad quirúrgica y la destreza no sean cuestiones de opinión, sino hechos cuantificables, medibles de forma precisa y sin ambigüedades. Este futuro ya está tomando forma, gracias a la convergencia de la medicina, la tecnología y en especial, la inteligencia artificial (IA). La cirugía laparoscópica, es una técnica de mínima invasión y recuperación más rápida, pero exige una destreza excepcional del cirujano (Figura 1). ¿Cómo, se podrían evaluar objetivamente estas habilidades? Es un desafío que la IA podría enfrentar y resolver.



Figura 1. Cirugía mediante la técnica de laparoscopía, que implica tiempo de recuperación más rápido y menor tamaño de cicatrices (imagen uso público tomada de `https://t.ly/2W1ju`).

Las señales electromiográficas (EMG), registros de la actividad eléctrica de los músculos, pueden ser indicadores efectivos del control que ejerce un cirujano durante una operación. Para interpretar estas señales, necesitamos técnicas sofisticadas de procesamiento de señales y, aquí es donde la IA entra en escena.

La IA, en su capacidad para procesar y analizar datos EMG, puede revelar detalles exactos sobre la eficacia y habilidad del cirujano. Esta técnica podría superar las limitaciones de los métodos de evaluación tradicionales y proporcionar una evaluación más objetiva y precisa [1].

Cirugía laparoscópica: Un vistazo al pasado y presente

La cirugía laparoscópica, o mínimamente invasiva, tuvo sus inicios a principios del siglo XX. Sin embargo, fue hasta final de los 80, con la popularización de la colecistectomía laparoscópica, que realmente transformó la cirugía [2]. Sus beneficios son evidentes: menores incisiones, reducción en infecciones, menor dolor y recuperación más rápida. La inclusión de cámaras de laparoscopia mejoró aún más la precisión quirúrgica [3].

Si bien su uso es extensivo en múltiples disciplinas quirúrgicas, como ginecología y urología, no está exenta de desafíos. La alta coordinación y destreza exigida representa una curva de aprendizaje muy inclinada para los aprendices.

Ante esta necesidad de precisión surge la cirugía robótica, destacando el sistema DaVinci. Esta tecnología replica los movimientos del cirujano con una precisión asombrosa, reduciendo incluso temblores [4]. No obstante, la pregunta persiste: ¿Cómo formamos y evaluamos con precisión a los cirujanos? Aquí es donde nuestro artículo se centra, explorando cómo la inteligencia artificial y el procesamiento de señales EMG pueden medir la habilidad quirúrgica.

Señales EMG y de Aceleración: Herramientas para Analizar la Destreza en Cirugía

El electromiograma (EMG) es una técnica que mide la respuesta eléctrica de los músculos a la estimulación nerviosa. Estas señales pueden proporcionar información sobre la función muscular y el control neuromuscular. En medicina, el EMG es ampliamente utilizado para diagnosticar enfermedades neuromusculares, evaluar el rendimiento en rehabilitación y, recientemente en el análisis de habilidades en cirugía [5].

Los sensores EMG y de aceleración: claves para evaluar la destreza quirúrgica.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

No obstante, la adquisición y el procesamiento de las señales EMG presentan desafíos. Estas señales son afectadas por artefactos de movimiento, ruido eléctrico y variaciones en la colocación del electrodo, entre otros factores. Los artefactos de movimiento son distorsiones no deseadas en los datos causadas por movimientos no intencionados, ocultando las verdaderas señales de interés. Aquí es donde las señales de aceleración entran en juego. Al combinar las señales EMG con las de aceleración, podemos discriminar mejor los artefactos de movimiento, lo que nos permite interpretar mejor los movimientos del cirujano.

Las señales de aceleración proporcionan información sobre las variaciones de velocidad con respecto al tiempo. Se adquieren usando acelerómetros, dispositivos que pueden detectar cambios dinámicos y estáticos en el movimiento. La aceleración ofrece una representación de la velocidad y la dirección del movimiento de un objeto. La aceleración es particularmente útil para identificar patrones rápidos de movimiento, cambios bruscos o sutiles vibraciones que podrían no ser evidentes solo a través de la observación directa o incluso con el análisis de señales EMG.

La idea de utilizar señales de aceleración en conjunción con EMG no es nueva. Se han utilizado juntas para mejorar la interpretación de los movimientos y la intención del usuario en diversas aplicaciones, como el control de prótesis y en deportes. Al aplicar esta idea al contexto de la cirugía, esperamos obtener una visión más clara de las habilidades y la destreza de los cirujanos, abriendo nuevas puertas para su evaluación y entrenamiento [6].

En la Figura 2, podemos observar un ejemplo de señales de EMG y de aceleración obtenidas durante una prueba de entrenamiento de los cirujanos laparoscópicos. Estas señales, a pesar de ser aparentemente caóticas y aleatorias, pueden contener información crucial acerca de la habilidad y la eficacia del cirujano durante el procedimiento.

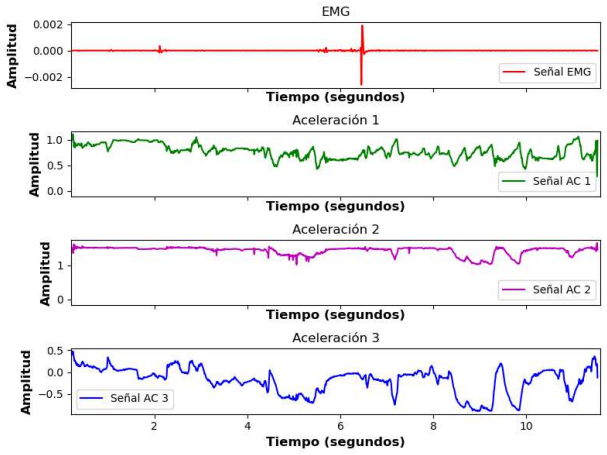


Figura 2. Señales de EMG y aceleración durante la realización de una tarea de entrenamiento laparoscópicousando el robot DaVinci (imagen propia).

La IA podría transformar la formación de los cirujanos, llevándola a nuevas alturas.

Inteligencia Artificial en la Evaluación de Habilidades en Cirugía: Potencialidades y Desafíos

La evaluación de las habilidades en cirugía tradicionalmente es subjetiva, basada en la observación y el juicio de expertos. Sin embargo, la IA está emergiendo como una herramienta prometedora para aportar objetividad y consistencia a este proceso.

La IA tiene la capacidad de manejar y analizar grandes cantidades de datos, lo que la hace perfecta para procesar las extensas señales de EMG y aceleraciones generadas durante una intervención quirúrgica. El primer paso en este proceso es la depuración de las señales. Esto implica filtrar el ruido y los artefactos, y segmentar las señales en partes manejables.

Una vez depuradas las señales, el siguiente paso es la extracción de características. Este proceso es esencial para transformar las señales en un conjunto de características que pueden ser fácilmente manejadas por los modelos de IA. Estas características pueden ser estadísticas simples, como la media y la desviación estándar de la señal, o medidas más complejas derivadas del análisis espectral o de la descomposición en componentes principales.

Finalmente, estos conjuntos de características se introducen en modelos de aprendizaje automático para la clasificación o la regresión, dependiendo del objetivo de la evaluación. Estos modelos pueden ser supervisados, en los que el modelo aprende a partir de ejemplos etiquetados de habilidades quirúrgicas buenas y malas, o no supervisados, donde el modelo descubre patrones y agrupa los datos sin ninguna orientación previa.

Los desafíos a superar incluyen la elección de las características correctas para extraer de las señales, la selección del modelo de IA más apropiado para el problema, y la obtención de datos de entrenamiento de alta calidad.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Casos de estudio resultados preliminares

Con el fin de explorar la aplicabilidad de la Inteligencia Artificial (IA) en la evaluación de habilidades quirúrgicas, realizamos un estudio experimental para adquirir señales durante tareas de laparoscopía. Empleamos el sistema Delsys Trigno para la adquisición de señales EMG y de aceleración. Este sistema permite la monitorización inalámbrica de la actividad muscular y el movimiento. Su portabilidad y precisión lo hacen una elección perfecta para el estudio.

En el experimento, se colocaron tres sensores Delsys Trigno en cada brazo de los participantes, específicamente en el antebrazo interno, antebrazo externo y bíceps, resultando en un total de seis sensores por sujeto, (ver Figura 3). Se seleccionaron 34 participantes de distintos perfiles, incluyendo 10 expertos en cirugía laparoscópica, 10 personal médico (cirujanos no laparoscópicos, médicos y enfermeras) y 14 personas de la población general (amas de casa, estudiantes, administrativos, etc.).



Figura 3. Participante realizando una de las pruebas con el módulo de entrenamiento del DaVinci, mientras se registran sus señales de EMG y aceleración en los brazos (imagen propia).

Los participantes realizaron tres tareas de entrenamiento laparoscópico utilizando el módulo de entrenamiento del sistema quirúrgico robótico Da Vinci. Las tareas consistieron en manipulación de instrumental laparoscópico y cámara.

Las señales recogidas durante este experimento proporcionan un gran volumen de datos, cada tarea dura aproximadamente tres minutos y cada sensor proporciona una señal EMG y tres señales de aceleración muestreadas a 2000 Hz y 148 Hz respectivamente. Estos datos representan un desafío debido a su volumen y su naturaleza estocástica. Además, las señales EMG pueden ser afectadas por artefactos de movimiento, y en algunos casos, incluso perderse completamente.

Para iniciar con el procesamiento de las señales elaboramos un programa en Python que permite importar y "limpiar"las señales, es decir, eliminar el ruido no deseado. Esta limpieza se logra con filtros digitales que eliminan componentes no deseados de la señal, eliminando interferencias. En situaciones donde hay datos faltantes o perdidos, se aplicó una técnica llamada interpolación, que permite rellenar esos espacios vacíos de manera coherente. La (Figura 4) es un ejemplo de una señal filtrada. El siguiente paso es el cálculo de ciertas métricas que aportarán información sobre las características y calidad de las señales, como el valor RMS (un tipo de promedio) y los puntos donde la señal alcanza sus valores más altos.

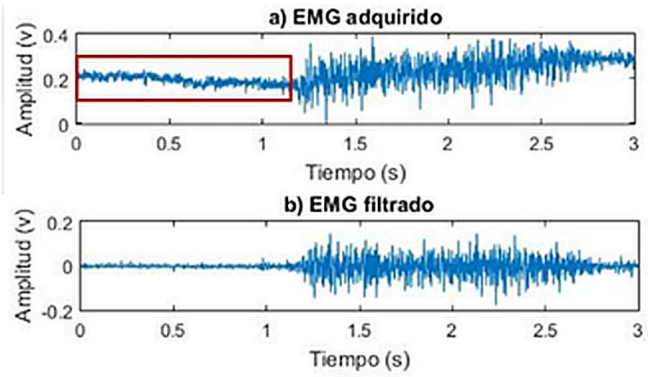


Figura 4. Señales de EMG adquiridas a) y filtradas b). Se puede observar cómo se eliminan variaciones atribuibles a artefactos de movimiento (imagen propia).

En la siguiente etapa del experimento se utilizarán estas características para entrenar un modelo de IA que pueda depurar las señales de manera automatizada. Existen varios modelos que podrían ser adecuados para esta tarea, como las Redes Neuronales Recurrentes (RNN) y las Máquinas de Vectores de Soporte (SVM). Las RNN son particularmente prometedoras debido a su capacidad para manejar secuencias de datos, que son comunes en el procesamiento de señales. Por otro lado, las SVM son conocidas por su eficiencia y su capacidad para manejar grandes espacios dimensionales, lo que podría ser útil dado el gran número de características que se pueden considerar.

En la Figura 5, se presenta la interfaz desarrollada en Python para el preprocesamiento de las señales, incluyendo la visualización de las señales EMG y de aceleración y el cálculo de sus valores RMS.

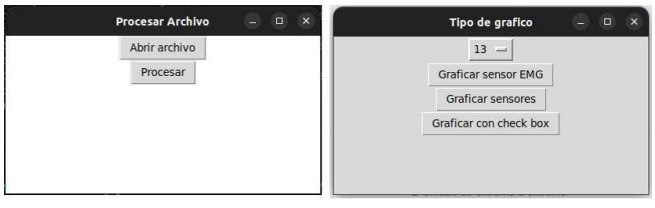


Figura 5. . Interfaz realizada en Python para aplicar el procesamiento a la señal seleccionada (imagen propia).

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Aunque aún queda mucho por hacer, pero se considera que la IA es una técnica prometedora en este campo de investigación.

Conclusiones

La fusión de tecnología y medicina ha revolucionado la cirugía laparoscópica, conocida por ser mínimamente invasiva y por sus rápidos tiempos de recuperación. A pesar de sus ventajas, exige una elevada destreza quirúrgica. Las señales electromiográficas (EMG) y de aceleración pueden ofrecer perspectivas sobre el rendimiento quirúrgico, pero analizarlas es complejo.

La inteligencia artificial (IA) tiene el potencial de transformar este análisis. Mediante la IA, es posible extraer características esenciales de los datos, reducir interferencias y diseñar modelos para evaluar destreza quirúrgica en tiempo real. Con técnicas avanzadas de procesamiento de señales, ya hemos obtenido métricas iniciales, y el siguiente paso es integrar modelos de IA para refinar estas métricas.

Con el progreso en IA y tecnología, nos acercamos a una era donde la evaluación quirúrgica será precisa y en tiempo real, elevando la calidad de la cirugía laparoscópica. Este cruce entre medicina, ingeniería y IA promete revolucionar la atención médica. Aunque el reto es grande, los beneficios son prometedores y merecen la inversión en investigación.✳

REFERENCIAS

1. Bilgic, E., Gorgy, A., Yang, A., Cwintal, M., Ranjbar, H., Kahla, K., Reddy, D., Li, K., Ozturk, H., Zimmermann, E., Quaiattini, A., Abbasgholizadeh-Rahimi, S., Poenaru, D. y Harley, J. M. (2022). Exploring the roles of artificial intelligence in surgical education: A scoping review. *The American Journal of Surgery*, 224(1, Part A), 205–216.

2. Alkatout, I., Mechler, U., Mettler, L., Pape, J., Maass, N., Biebl, M., Gitas, G., Laganà, A. S. y Freytag, D. (2021). The Development of Laparoscopy—A Historical Overview. *Frontiers in Surgery*, 8.

3. Cuschieri, A. (2005). Laparoscopic surgery: Current status, issues and future developments. *The Surgeon*, 3(3), 125–138.

4. D'Ettorre, C., Mariani, A., Stilli, A., Rodriguez y Baena, F., Valdastri, P., Deguet, A., Kazanzides, P., Taylor, R. H., Fischer, G. S., DiMaio, S. P., Menciassi, A. y Stoyanov, D. (2021). Accelerating Surgical Robotics Research: A Review of 10 Years With the da Vinci Research Kit. I*EEE Robotics & Automation Magazine*, 28(4), 56–78.

5. Shugaba, A., Lambert, J. E., Bampouras, T. M., Nuttall, H. E., Gaffney, C. J. y Subar, D. A. (2022). Should All Minimal Access Surgery Be Robot-Assisted? A Systematic Review into the Musculoskeletal and Cognitive Demands of Laparoscopic and Robot-Assisted Laparoscopic Surgery. *Journal of Gastrointestinal Surgery*, 26(7), 1520–1530.

6. Thurston, T., Dolan, J. P., Husain, F., Stroud, A., Funk, K., Borzy, C. y Zhu, X. (2022). Assessment of muscle activity and fatigue during laparoscopic surgery. *Surgical Endoscopy*, 36(9), 6672–6678.

SOBRE LOS AUTORES



Naidelyn Linares Guzmán nació en Toluca, Estado de México en el año 2001, actualmente es estudiante en la carrera de Ingeniería en Computación en la Universidad Autónoma del Estado de México. Participa como becaria en el sistema de información científica Redalyc red de revistas científicas, participando como desarrolladora *front-end*. Sus intereses son el desarrollo de videojuegos y aplicaciones de la inteligencia artificial.



Oscar Franco Juan nació en Toluca, Estado de México en el año 2000, actualmente realiza actividades de desarrollador back-end en el sistema de información científica Redalyc red de revistas científicas. Estudiante de ingeniería en computación en la Universidad Autónoma del Estado de México. Sus intereses son el desarrollo de inteligencia artificial aplicadas al procesamiento y análisis de bioseñales.



Juan Hereiva Osorio nació en Toluca, Estado de México, actualmente estudiante de ingeniería en computación en la Universidad Autónoma del Estado de México. Además, se desempeña como tester en la empresa Kimerkia S.A de C.V, desarrolladora de páginas web y aplicaciones móviles en el área automotriz. Sus intereses de investigación son el análisis de datos para identificar patrones de consumo de contenido multimedia.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691



Rigoberto Martínez Méndez obtuvo el título de ingeniero en electrónica por el ITA, el grado de maestro en ciencias en bioelectrónica por el CINVESTAV, México y recibió el grado de Ph.D en biomédica por la Universidad de Chiba en Japón en 2011. Actualmente es miembro del SNI nivel I y se desempeña como profesor e investigador en la UAEMex. Sus intereses de investigación incluyen el análisis de bioseñales y el desarrollo de dispositivos biomédicos portables no invasivos.



Rosa María Valdovinos Rosas es Dra. en Ciencias Computacionales, miembro del SNI nivel II. Ha participado en más de 15 proyectos de investigación con impacto social y científico, además cuenta con producción en revistas indizadas, capítulos de libro, publicaciones en congresos, libros, conferencias dictadas y una patente otorgada. Ha formado estudiantes de licenciatura, Maestría y Doctorado. Participa en la organización de eventos para la divulgación de la ciencia y despertar vocaciones tempranas. Su producción científica ha obtenido más 1000 citas, con un índice H14 y es una de las 10,000 científicas más influyentes a nivel Nacional, de acuerdo con el International AD Scientific index 2023.



Daniel Lorias Espinoza nació en Guaymas, Sonora, México, en 1974. Obtuvo los grados de M.S. y Ph.D. en Ingeniería Eléctrica del CINVESTAV, Ciudad de México, México, en 2004 y 2008, respectivamente. Desde 2010, ha sido Profesor de Investigación en CINVESTAV, Ciudad de México, México. Es miembro del Sistema Nacional de Investigadores (SNI-1). Sus intereses actuales de investigación incluyen tecnologías percutáneas y mínimamente invasivas.

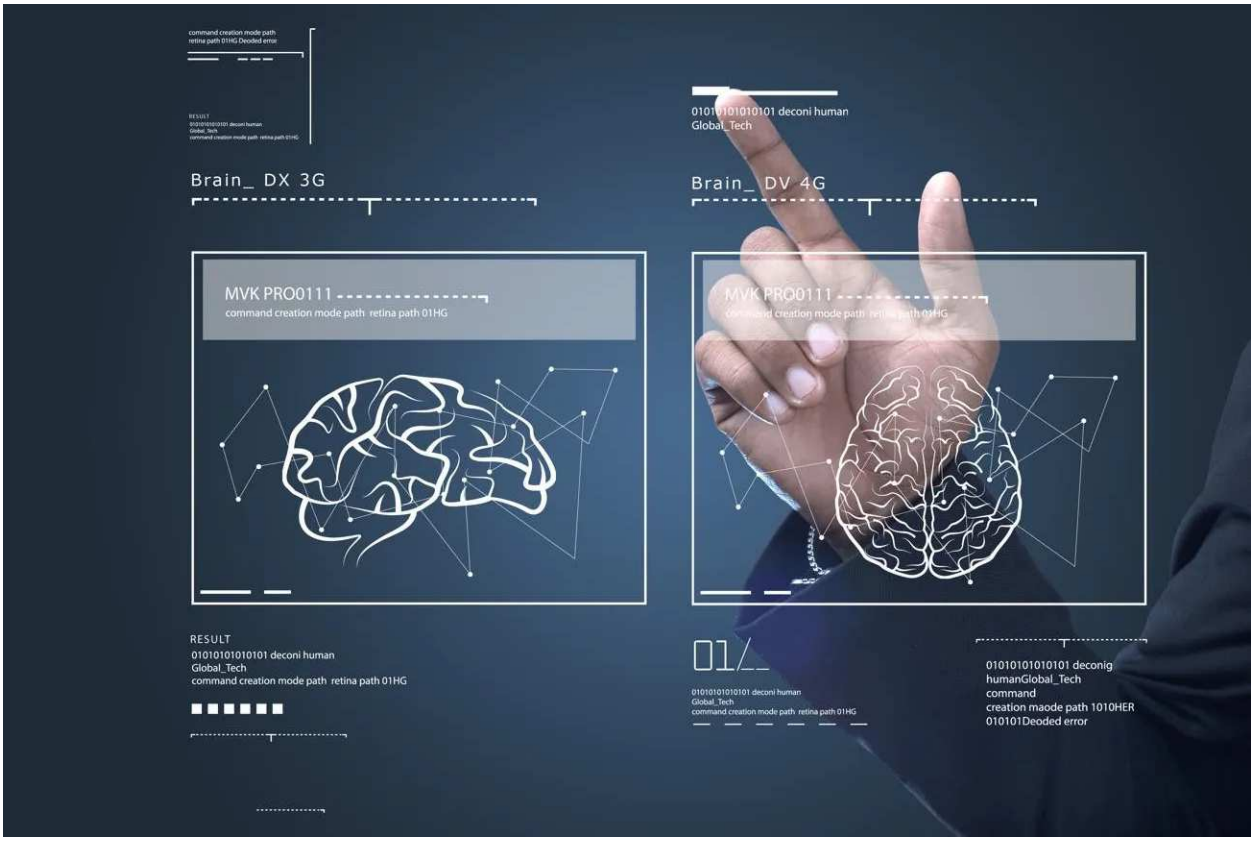


Imagen tomada de: https://revistamedica.com/cirugia-asistida-por-inteligencia-artificial-avances-aplicaciones/.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Detección de peatones con termografía y visión artificial aplicado en seguridad vial

Gerardo Bobadilla Valencia, Víctor Hugo Benítez Baltazar y Jesús Horacio Pacheco Ramírez

En esta investigación se estudia si una cámara térmica de baja resolución (80 x 60 pixeles) con la integración de algoritmos de inteligencia artificial y dispositivos IoT, es adecuada para aplicarse en seguridad vial, en específico con la detección de personas (peatones) en condiciones de baja visibilidad. Estadísticamente se ha comprobado que los accidentes de tránsito de mayor gravedad se presentan en condiciones de poca visibilidad o durante la noche. La principal característica de las cámaras térmicas es que generan imágenes mediante la detección de radiación infrarroja, siendo ideales para ser aplicada en situaciones donde la visión humana está limitada por poca o prácticamente nula luminosidad. Planteamos que, usando una cámara de baja resolución y la detección automática de objetos mediante algoritmos de visión artificial, es posible disponer de una herramienta útil en la seguridad vial.

Los accidentes de tránsito de mayor gravedad se presentan en condiciones de poca visibilidad o durante la noche.

Introducción

El desarrollo tecnológico actual en el campo de la seguridad vial nos brinda mejores condiciones para prevenir o evitar accidentes. Hay circunstancias en las que aun teniendo la pericia y reflejos adecuados la conducción, estos no son suficientes, como es el caso de la poca o nula visibilidad. Se presenta una posible estrategia de asistencia en la conducción de automóviles que pudiera aplicarse en condiciones normales y de poca visibilidad. Dado que las cámaras térmicas generan imágenes al detectar el calor o radiación infrarroja de los cuerpos, es ideal para ser aplicada como un apoyo o sistema redundante de manejo, además se plantea la automatización de detección de objetos mediante la aplicación de algoritmos de inteligencia artificial.

Objetivo

El objetivo es diseñar un sistema que tenga la capacidad de reconocer personas en imágenes térmicas, mediante el análisis con algoritmos de visión artificial. Para esto se seleccionarán algoritmos de visión artificial adecuados para detección de personas en imágenes térmicas de baja resolución, así como también se seleccionará una cámara térmica comercial de baja resolución.

Planteamiento del problema

Según el "Governors Highway Safety Association" en condiciones de baja luminosidad o en la noche es cuando sucede un porcentaje más elevado de accidentes mortales de peatones[1]. En México según datos del 2021 (Figura 1), el mayor número de decesos ocurrió entre las 18:00 y las 23:59 horas, con 1,473 (33.5 %) personas fallecidas. Para el caso de las víctimas heridas, entre las 18:00 y las 23:59 horas se registraron 27,460 (33.3 %) personas lesionadas. [2].

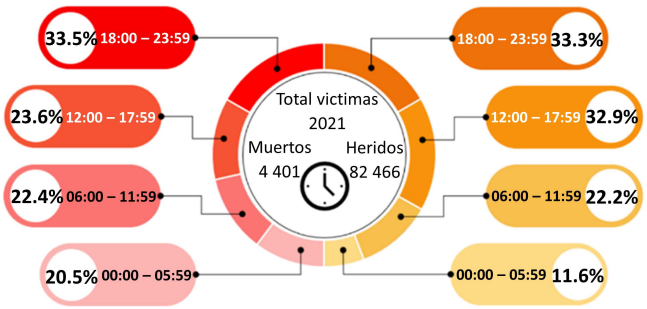


Figura 1. Distribución porcentual de víctimas fallecidas y lesionadas en accidentes viales, por horario 2021 en México[2].

Incluso en sistemas de alta tecnología, como los vehículos autónomos, se han presentado accidentes fatales por no contar con un sistema redundante, como fue el caso en Marzo de 2018 en Arizona Estados Unidos, donde un Uber autónomo golpeo de manera mortal a un peatón, lo cual, según el reporte de las autoridades fue debido a la visibilidad nocturna limitada y el radar y los sistemas LIDAR (sistema de medición y detección de objetos mediante láser) que no clasificaron correctamente al peatón (aunque fue detectado 5.6 segundos antes del impacto), además de que el operador que monitoreaba el vehículo estaba distraído con su celular, ello dio como resultado un accidente fatal. Lo anterior es un claro ejemplo de cómo con el apoyo de un sistema de imágenes

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

térmicas pudiera haber aumentado la tasa de detección y probablemente se hubiese salvado una vida [3]. Dada esta problemática se propone estudiar la viabilidad de un sistema automático de detección de personas utilizando algoritmos de visión artificial y cámaras de visión térmica de baja resolución (resolución 80 x 60 pixeles).

Incluso en sistemas de alta tecnología, como los vehículos autónomos, se han presentado accidentes fatales.

Estado del Arte

La Unión Europea en su plan "Visión Cero" hará obligatorios diversos dispositivos tales como la caja negra, el alcoholímetro anti-arranque y otras ayudas a la conducción. Actualmente se incluyen sistemas de asistencia en la conducción en los vehículos de nueva generación, lo cual pretende reducir los accidentes [4].

Aprendizaje profundo

El aprendizaje profundo es un tipo de aprendizaje automatizado, en el cual se utilizan redes neuronales artificiales con una jerarquía establecida, donde en cada nivel se extraen las características significativas del nivel anterior a esta jerarquía se le conoce como capas del modelo neuronal [5].

Imágenes térmicas

Tal y como demostró el físico Max Planck, existe una correlación entre la temperatura de un cuerpo y la intensidad de la radiación infrarroja que emite. Una cámara termográfica mide la onda larga de la radiación infrarroja recibida en el campo de visión (Figura 2), a partir de la cual calcula la temperatura del objeto a medir. El cálculo tiene en cuenta la emisividad (ε) de la superficie del objeto medido, así como la compensación de la temperatura reflejada (RTC); estas dos variables se pueden ajustar manualmente en la cámara termográfica [6].

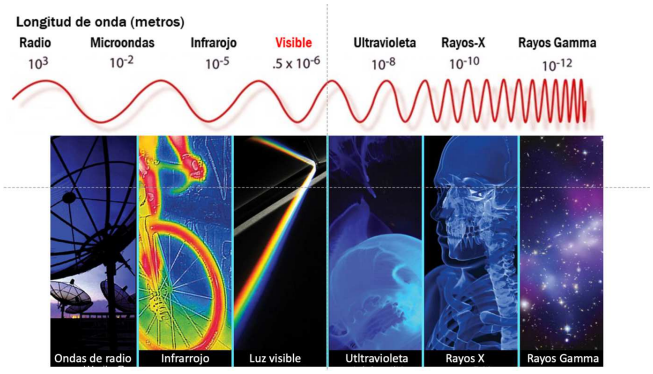


Figura 2. Espectro electromagnético y las imágenes que se pueden obtener [7].

Metodología

La investigación se desarrolla siguiendo las fases del proceso planteado en la Figura 3. Seleccionado el algoritmo se prepararán las imágenes térmicas para entrenar el modelo, posteriormente una validación de este para determinar si los resultados cumplen con el objetivo planteado. Finalmente se realizará una prueba de concepto con la integración del modelo entrenado.

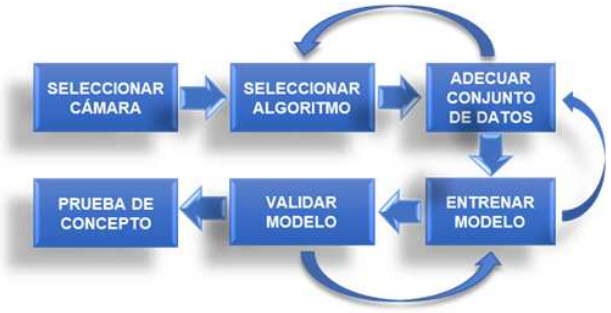


Figura 3. Fases del proceso de investigación.

Resultados

Una vez establecida la metodología, se implementa la investigación y posteriormente se muestran los resultados obtenidos.

Algoritmos y modelos

Se trabaja con el algoritmo YOLOv8 y sus modelos de detección (Tabla 1), Particularmente se utiliza para estas pruebas el modelo nano y extragrande[8].

Tabla 1. Modelos de detección de YOLOv8[8].

Model	size (pixels)	mAP^{val} 50-95	Speed CPU ONNX (ms)	Speed A100 TensorRT (ms)	params (M)	FLOPs (B)
YOLOv8n	640	37.3	80.4	0.99	3.2	8.7
YOLOv8s	640	44.9	128.4	1.20	11.2	28.6
YOLOv8m	640	50.2	234.7	1.83	25.9	78.9
YOLOv8l	640	52.9	375.2	2.39	43.7	165.2
YOLOv8x	640	53.9	479.1	3.53	68.2	257.8

Adquisición de imágenes

Para el desarrollo de la prueba se utilizó la cámara IP Imagen Dual IDIS modelo DC-TH2011 (Figura 4), la cámara Térmica es de 80 (h) x 60 (v) pixeles y la real de 1280 x 960 pixeles [9].

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691



Figura 4. Cámara IP Imagen Dual IDIS modelo DC-TH2011.

Se recabaron imágenes en campo, la Figura 5 muestran la configuración utilizada para la captura de videos, de estos se extrajeron alrededor de 26,000 imágenes, posteriormente (para ahorrar tiempo de entrenamiento) estas se recortaron a un tamaño de 640X640 pixeles.



Figura 5. Configuración para captura de videos.

Entre el conjunto de imágenes se seleccionó aquella que tuvieran personas, las cuales resultaron alrededor de 5,500.

Preprocesamiento de datos

Las imágenes se etiquetaron con el formato YOLO, posteriormente el conjunto de datos fue separado en 2 distribuciones, la primera, con 75 % para entrenamiento y 25 % para validación; la segunda, con un 90 % para entrenamiento y 10 % de validación (misma semilla de aleatoriedad). En las tablas 2 y 3 se presentan los resultados de los entrenamientos con 3,733 imágenes de entrenamiento y 1,245 de validación, en equipos con GPU'S, los datos están ordenados por épocas de entrenamiento. Las métricas de precisión van evolucionando a medida que aumentan el número de épocas de entrenamiento, es importante monitorearlas para no caer en un sobre entrenamiento del sistema.

Tabla 2. Entrenamiento diferentes épocas del modelo YOLOv8n.

Épocas	Memoria de GPU	Tiempo (Horas)	métricas/ precision(B)	métricas/ recal(B)	métricas/ mAP50(B)	métrcas/ mAP50-95(B)	Entorno de ejecución
1	2.26G	0.041	0.907	0.886	0.94	0.626	Kaggle - GPUT4x2
10	2.62G	0.362	0.966	0.963	0.99	0.75	Colab - GPUT4
15	2.99G	0.503	0.964	0.979	0.992	0.774	Colab - GPUT4
20	2.78G	0.773	0.982	0.98	0.993	0.786	Colab -GPUT4
30	2.99G	1.215	0.979	0.985	0.993	0.801	Colab - GPUT4
50	2.99G	1.985	0.993	0.984	0.995	0.819	Colab - GPUT4
100	2.78G	4.718	0.99	0.99	0.995	0.83086	Colab - GPUT4
150	2.76G	5.881	0.99	0.995	0.995	0.83107	Kaggle - GPUT4x2
175	2.76G	5.921	0.992	0.992	0.995	0.831	Kaggle - GPUT4x2
198	2.76G	7.362	0.991	0.99	0.995	0.831	Kaggle - GPUT4x2

Al entrenar a 200 épocas, el modelo YOLOv8n se detuvo a las 198 ya que el algoritmo detecto que habían pasado 50 épocas sin cambios. El tamaño de los modelos es de 6.2MB para el YOLOv8n y 136.7MB para YOLOv8x, con el modelo YOLOv8x se entrenó hasta 75 épocas (0.83 de mAP50-95). Se utilizo el modelo YOLOv8n a 198 épocas (yolov8n_200e.pt) para la prueba de concepto en una transmisión RTSP (del inglés Real Time Streaming Protocol) de la cámara térmica.

Tabla 3. Entrenamiento del modelo YOLOv8x.

Épocas	Memoria de GPU	Tiempo (Horas)	métricas/ precision(B)	métricas/ recall(B)	métricas/ mAP50(B)	métrcas/ mAP50-95(B)	Entorno de ejecución
1	13G	0.102	0.934	0.93	0.977	0.707	Kaggle - GPUT4x2
10	13.2G	0.920	0.956	0.972	0.989	0.755	Kaggle - GPUT4x2
10	14.2G	2.214	0.954	0.976	0.989	0.751	Kaggle - GPU P100
15	15.4G	1.463	0.967	0.982	0.992	0.784	Colab - GPUT4
20	13G	1.906	0.977	0.979	0.993	0.795	Kaggle - GPUT4x2
50	13G	4.765	0.987	0.988	0.994	0.828	Kaggle - GPUT4x2
75	13G	6.808	0.99	0.988	0.994	0.83	Kaggle - GPUT4x2

Prueba de concepto

Para la prueba de concepto se enfocó en crear un dispositivo funcional con IoT y que permita la integración del modelo de inteligencia artificial entrenado de una manera práctica. Para tales fines se trabajó con la cámara térmica IP IDIS y con la plataforma embebida Rapberry Pi, además de una pantalla tactil de 7 pulgadas como monitor del dispositivo. El dispositivo consiste en la integración de una pantalla OEM tactil de 7 pulgadas a la tarjeta embebida el proceso de instalación se muestra en la Figura 6.



Figura 6. Dispositivo de prueba de concepto.

El tiempo de respuesta de detección en la Raspberry 4 Modelo B con 4 GB de RAM, fue de aproximadamente 1 cuadro o fotograma analizado por segundo, no con el suficiente desempeño para poder ser considerado una respuesta en tiempo real (entre 15 y 30 fotogramas por segundo), pero si para demostrar la funcionalidad y la viabilidad de la aplicación en la prueba de concepto. En las Figura 6 se muestra cómo se simula la neblina con una maquina generadora de humo.



Figura 7. Prueba de concepto con neblina.

Las Figuras 8 y 9 se presentan los resultados del dispositivo que integra el modelo de IA, donde se aprecia momentos de falsos positivos (En la Figura 8 se detecta 2 personas, pero realmente solo hay una) y detección de una persona con 85 % de probabilidad.

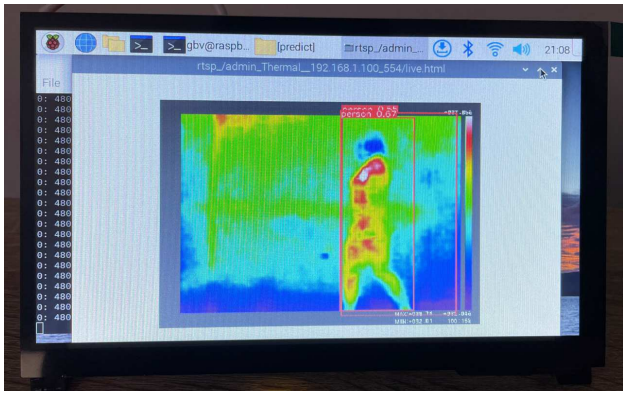


Figura 8. Resultados de prueba de concepto (falsos positivos).

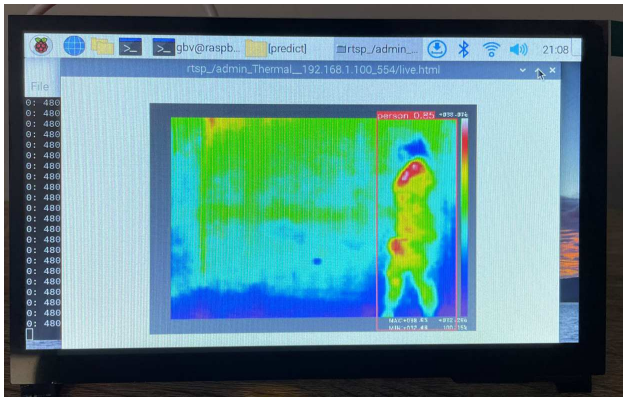


Figura 9. Resultados de prueba de concepto.

Conclusiones

Como podemos observar en los resultados, la utilización de este tipo de cámaras comerciales con baja resolución, son factibles para ser utilizadas con algoritmos de inteligencia artificial para dar un soporte al momento de conducir un vehículo. Para trabajos a futuro los tiempos de respuesta son mejorables al utilizar dispositivos IoT con mejores prestaciones. Esta investigación sirve como base para desarrollar otras aplicaciones con este tipo de cámaras como detección de fallas en motores eléctricos, búsqueda y rescate de personas, detección de cáncer, alertas de incendios entre otros.✷

REFERENCIAS

1. Richard Retting Sam Schwartz Consulting. (2017). Pedestrian Traffic Fatalities by State. Accedido: 7 de mayo de 2022. [En línea]. Disponible en: https://www.ghsa.org/sites/default/files/2018-02/pedestrians18.pdf.

2. COMUNICACIÓN SOCIAL INEGI. (2022). COMUNICADO DE PRENSA NÚM. 662/22 17 DE NOVIEMBRE 2022 PÁGINA 2/6 COMUNICACIÓN SOCIAL, 2022. Accedido: 27 de febrero de 2023. [En línea]. Disponible en: https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2022/EAP_VICACCT22.pdf.

3. National Transportation Safety. (2019). Highway Accident Report: Collision Between Vehicle Controlled by Developmental Automated Driving System and Pedestrian, Tempe, Arizona, March 18, 2018, 2019. Accedido: 4 de septiembre de 2022. [En línea]. Disponible en: https://www.ntsb.gov/investigations/AccidentReports/Reports/HAR1903.pdf.

4. Kountoura, E. (2021). INFORME sobre el Marco de la política de la Unión Europea en materia de seguridad vial para 2021-2030 – Recomendaciones sobre los próximos pasos hacia la "Visión Cero", jun. 2021. Accedido: 7 de mayo de 2022. [En línea]. Disponible en: https://www.europarl.europa.eu/doceo/document/A-9-2021-0211_ES.pdf.

5. Silva, E. (2020)."Entrenamiento de la Red Neuronal Convolucional YOLO para objetos propios. México, marzo de 2020. Disponible en: https://biorobotics.fi-p.unam.mx/wp-content/uploads/Courses/reconocimiento_de_patrones/tutoriales/YOLO-Introducci%C3%B3n-e-implementaci%C3%B3n-.pdf.

6. Testo, A. (2008). Termografía, guía de bolsillo Teoría-Aplicación Práctica-Consejos y Trucos. Disponible en: http://www.ait-orsenor.com/testo_guia.pdf.

7. Hernández, A. y Martínez, H. (2023). La tecnología infrarroja usada en termómetros, Accedido: 13 de junio de 2023. Disponible en: https://acmor.org/publicaciones/la-tecnologa-infrarroja-usada-en-term-metros.

8. Jocher, G., Chaurasia, A. y Qiu, J. (2023). YOLO by Ultralytics. Accedido: 23 de abril de 2023. [En línea]. Disponible en: https://github.com/ultralytics/ultralytics.

9. IDIS. (2023). DC-TH201x Installation Guide Thermal Cameras DC-TH Series. Accedido: 27 de febrero de 2023. [En línea]. Disponible en: https://idisglobal-admin.s3-accelerate.amazonaws.com/support_download/DC-TH201x+Installation+Guide.pdf.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

SOBRE LOS AUTORES



Gerardo Bobadilla Valencia es Ingeniero en Electrónica por el Instituto Tecnológico de Hermosillo Sonora, México. Actualmente está en busca del Posgrado MIIoT & IA (Maestría en Ingeniería en Internet de las Cosas e Inteligencia Artificial) De 2009 a 2014 se desempeñó como Ingeniero de diseño Electrónico en el departamento de "Power Line Communication" para la Comisión Federal de Electricidad en México. Dentro de la misma empresa de 2014 a 2015 como Ingeniero en Telecomunicaciones y de 2015 a la fecha se desempeña como Ingeniero en Sistemas Computacionales.



Víctor H. Benítez received the B.E. degree in electronics from the Universidad de Guadalajara, Mexico, in 1999, and the M.Sc. and Ph.D. degrees in electrical engineering from the Advanced Studies and Research Center, CINVESTAV-IPN, in 2002 and 2009, respectively. He has worked in the manufacturing industry related to the manufacture of printed circuits boards, and in the área of testing engineering. He is currently a Full Professor of mechatronics with the Industrial Engineering Department, Universidad de Sonora. His research interests include myoelectric control systems, neural networks applied to control electromechanical systems, and embedded systems applied to the Internet of Things.



Jesús Pacheco received the bachelor's degree in electronics engineering with a focus on digital systems and the M.Sc. degree in computer science from the Tecnológico de Hermosillo and the Ph.D. degree from the Electrical and Computer Engineering Department, The University of Arizona. He is currently a Full Professor with the Industrial Engineering Department, Universidad de Sonora, and the Director of the NSF Center for Cloud and Autonomic Computing. His research interests include cyber security for the Internet of Things and cyber-physical systems.

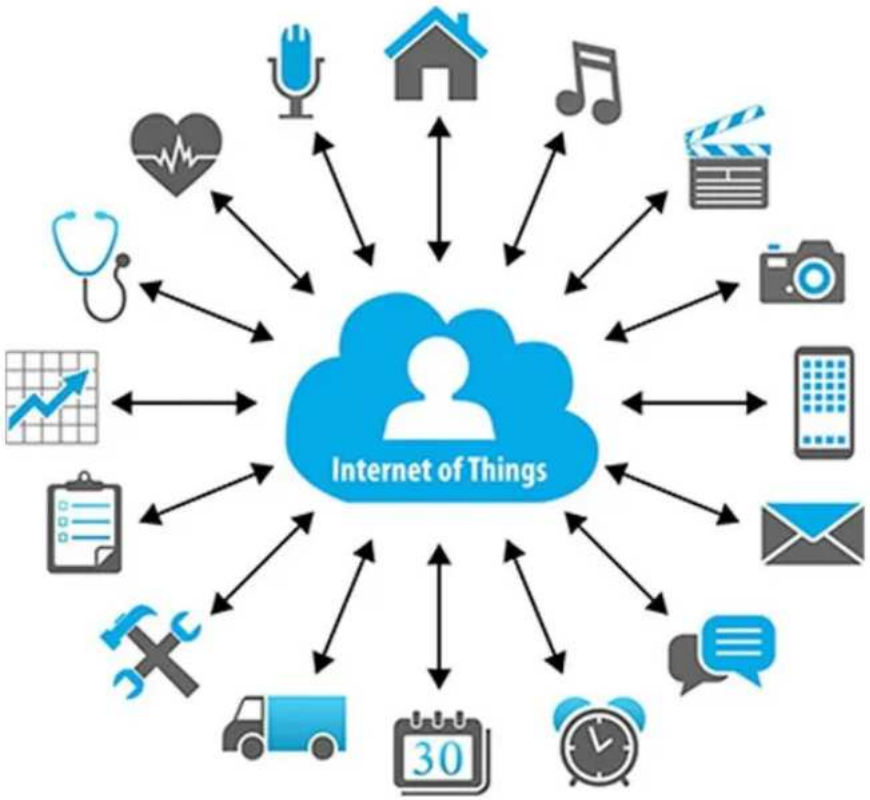


Imagen tomada de:
https://medium.com/@bmuha1/what-is-the-iot-introduction-to-the-internet-of-things-57335391cd5f.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Propuesta de un algoritmo genético para establecer proformas en proyectos de construcción

José Manuel Pérez Esquivel, Cristina Juárez Landín y Marco Alberto Mendoza Pérez

Introducción

La Línea Base de una obra civil es un plan detallado que se utiliza como punto de referencia para medir el progreso del proyecto y como marco de información para la gestión de los cambios y la monitorización del avance trabajado. Se define como Línea Base de Alcance a la versión aprobada de un proyecto estableciendo su magnitud, que sólo se puede modificar a través de procedimientos formales de control de cambios y que se utiliza como base de comparación [2]. Esta línea base se establece en la fase de planificación del proyecto y es un elemento fundamental para la gestión de proyectos en la construcción. La elaboración de proformas en proyectos de construcción es un proceso crucial para determinar los costos y estimar los recursos necesarios para la ejecución de un proyecto, sin embargo, el establecimiento de nuevas proformas puede ser un proceso complejo y costoso en términos de tiempo y recursos humanos.

En la guía del Project Management Body of Knowledge (PMBOK) del Project Management Institute (PMI), se describen los procesos necesarios para la gestión de proyectos en la construcción, y se dedica una sección específica a la gestión del cronograma y la gestión de los costos. Estas secciones son esenciales para la elaboración de la línea base del proyecto porque permiten establecer los plazos, los costos y los recursos necesarios para la realización de la obra convirtiéndose en un marco de referencia para medir el desempeño del proyecto y comparar el progreso actual y real con el planificado. En caso de que se surjan desviaciones es posible identificar las causas y tomar las medidas necesarias para corregir el rumbo. Por lo tanto, la línea base es una herramienta esencial para la toma de decisiones informadas y la gestión eficaz del proyecto.

Otra técnica para el control de proyectos es la del Valor Ganado que determina el desempeño del proyecto durante su ejecución mediante el cual se controla la gestión integrada del alcance, el cronograma y los costos. Específicamente, esta técnica compara el desempeño de la línea base con respecto al desempeño real en términos del cronograma y costos [2], en otras palabras, la práctica del valor ganado mide la eficiencia y la eficacia del proyecto, y como se están utilizando los recursos (tiempo y dinero) en comparación con lo que se planeó inicialmente.

Para llevar a cabo la gestión del valor ganado, se deben establecer tres medidas principales [10]: el Valor Planificado (VP), el Costo Real (CR) y el Valor Ganado (VG). El Valor Planificado representa el presupuesto asignado para el trabajo que se debe realizar durante un período de tiempo determinado. El CR representa el costo histórico de ese trabajo en ese período de tiempo, y el VG representa el valor del trabajo completado hasta el periodo que se esté revisando, de acuerdo con el plan inicial. Con estas tres medidas, se pueden calcular los indicadores claves de la gestión del valor ganado como la Variación de costo (VC) se calcula $VC = VG - CR$, el Índice de Desempeño de Costo (IDC) calculado con $IDC = VG/CR$, el Valor Ganado programado (VGP) se calcula $VGP = VG - VP$ y el Índice de Desempeño del Cronograma (IDC) se calcula $IDC = VG/VP$.

En la Figura 1 se representa la gráfica Curva S, resultado de la técnica del VG, esta gráfica está en función del tiempo total del proyecto donde se puede apreciar la comparativa entre el VP, VG y CR.



Figura 1. Curva S de un proyecto con fecha de corte en marzo 2015.

En gestión de proyectos, la Línea Base de Alcance y Valor Ganado controlan los costos y el cronograma del proyecto asegurando el éxito.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

La investigación de corte cuantitativo-descriptiva se enfocará en el análisis detallado del uso de algoritmos genéticos en proformas de proyectos de ingeniería civil.

Una proforma se refiere a un presupuesto o pronóstico de costos para un proyecto de construcción, se puede visualizar como una Línea Base en la que intervienen el valor ganado y el costo real. Es una herramienta importante para el desarrollo de un proyecto y ayuda a tomar decisiones sobre la distribución de los costos asociados con la construcción, como los materiales, la mano de obra, el equipo y los permisos. El objetivo es mantener o modificar la planeación de tal forma que se mantenga la planeación original (línea base) en la ejecución del proyecto este método se realiza cada trimestre teniendo cuatro proformas en el año denominados 00+12, 03+09, 06+06 y 09+03, los primeros dos dígitos se refieren a los meses con el valor del costo real del proyecto y los últimos dos a los meses restantes en la planeación. Inicialmente, se dispone de un software que ha optimizado el proceso de elaboración de proformas, aunque la intervención humana aún implica un tiempo considerable. La meta es incorporar la inteligencia artificial al software para disminuir aún más el tiempo necesario en la generación de proformas.

Un algoritmo genético es un enfoque metaheurístico que permite la optimización de problemas complejos y difíciles [3]. Está técnica de optimización inspirada en la evolución natural, particularmente en la genética, se pueden utilizar para mejorar la elaboración de proformas en proyectos de construcción y obras civiles optimizando la selección de los insumos y procesos involucrados en la elaboración de proformas. Identificando las variables y parámetros más importantes que afectan el costo y el tiempo del proyecto y posteriormente optimizando estos parámetros se puede cumplir el objetivo de minimizar los costos y maximizar la eficiencia del proyecto.

En la práctica, se pueden utilizar los algoritmos genéticos para generar una población de soluciones candidatas que representan diferentes combinaciones de los parámetros relevantes del proyecto. Luego, se aplican operadores genéticos, como la selección, el cruce y la mutación, para combinar las soluciones existentes y generar nuevas soluciones. En la Figura 2, se muestra el diagrama de flujo para elaborar una proforma en el cual se indica el momento en que el algoritmo genético sera utilizado.

La mejor manera de integrar la inteligencia artificial y los algoritmos genéticos en la planificación y la toma de decisiones en proyectos de construcción es mediante el desarrollo de un sistema que pueda recopilar y procesar datos en tiempo real. Este sistema deberá permitir la integración de diferentes fuentes de datos, como la información de los recursos, los cronogramas, los costos y los riesgos para utilizar técnicas de inteligencia artificial y algoritmos genéticos donde se analizan los datos y generar soluciones óptimas para la planificación y la toma de decisiones. El sistema también debería ser lo suficientemente flexible para permitir la adaptación a diferentes proyectos y a diferentes fases del ciclo de vida del proyecto. Deberá ser capaz de generar escenarios y simulaciones basados en diferentes condiciones y supuestos, y proporcionar a los gestores de proyectos información clara y concisa para la toma de decisiones.

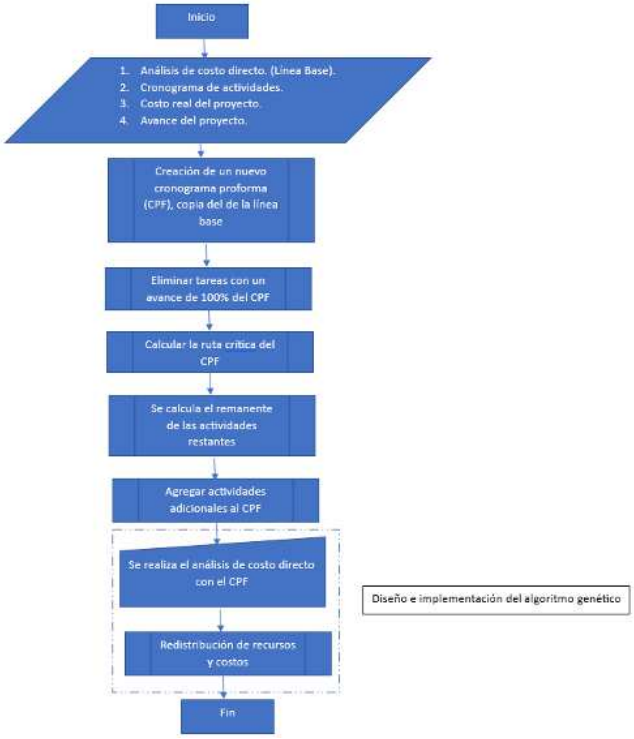


Figura 2. Diagrama de flujo para elaborar proformas.

La implementación de algoritmos genéticos en la planificación y ejecución de proyectos de construcción puede tener una serie de beneficios, como la reducción de los tiempos en el establecimiento de proformas, la mejora en la precisión de la predicción de actividades y la distribución de costos y tiempos, mejorando la toma de decisiones en la planificación. En definitiva, el uso de algoritmos genéticos y otras tecnologías avanzadas puede

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

transformar la forma en que se planifican y ejecutan los proyectos de construcción, permitiendo una mayor eficiencia, precisión y calidad de servicio.

Como objetivo se contempla diseñar e implementar un modelo de algoritmos genéticos para la elaboración de proformas en proyectos de construcción y obras civiles para ayudar a mejorar eficiencia en la planificación de proyectos brindando una predicción de costos.

Método

Una investigación de corte cuantitativo-descriptiva será útil para entender y analizar el uso de algoritmos genéticos en la elaboración de proformas en obras civiles, observando detalladamente los procesos y metodologías empleados en la utilización de los algoritmos genéticos para establecer proformas, así como los resultados obtenidos y las posibles limitaciones o desafíos encontrados en su implementación. Además, se podrían realizar comparaciones con otras técnicas de elaboración de proformas en obras civiles, para determinar cuál es más efectiva en términos de precisión y eficiencia.

Se propone usar inteligencia artificial mediante algoritmos evolutivos, esta sección de algoritmos están compuestos por distintos métodos como la programación genética, que consiste en la evolución automática, para pasar a ser un programa usando ideas basadas en la selección natural, se busca que el sistema evolucione para el establecimiento de proformas de los proyectos de la ingeniería civil para ayudar al personal de control de proyectos a obtener el valor ganado más cercano al valor planeado. A continuación, se presentan las fases de los algoritmos genéticos:

1. En la **inicialización** se definirá el conjunto de variables que intervienen en una proforma, como los costos en los diferentes tipos de recursos (materiales, mano de obra, maquinaria, fletes, subcontratos) y el tiempo de las actividades definidas y otorgar limites como tiempo disponible, precios, salarios y costo de renta.
2. En la **selección** es posible que se utilicen una combinación de diferentes estrategias. La selección de los cromosomas que van a transmitir información genética a las siguientes generaciones se hace con base en su aptitud [9]. Las selecciones principales que pueden ser de utilidad es la selección por torneo en la cual se eligen varios individuos aleatorios de la población actual y se comparan sus valores de aptitud para determinar cuál de ellos es el mejor candidato para la siguiente generación. La selección por ranking en la cual se ordenan los individuos de la población actual según su valor de aptitud y se seleccionan los mejores individuos para la siguiente generación. La selección por elitismo que garantiza que los mejores individuos de la población actual se mantengan en la siguiente generación.
3. En los **operadores genéticos** de igual forma que en la selección se pueden utilizar una combinación de operadores genéticos, los que son de interés para esta investigación es el operador crossover (cruce) donde se toman dos o más soluciones candidatas (individuos) de la población actual y combinar partes de sus soluciones para crear nuevas soluciones candidatas, La inserción y eliminación implican agregar o eliminar actividades en una solución candidata y el intercambio de dos o más componentes de una solución candidata para crear una nueva solución.
4. En la **evaluación** se considera el desempeño de cada solución candidata en la población actual y se asigna una puntuación o valor de aptitud (fitness) a cada una de ellas. Los valores de aptitud se utilizan para seleccionar las mejores soluciones candidatas para la siguiente generación del algoritmo genético. La evaluación es una fase crítica en los algoritmos genéticos para la optimización, los criterios de desempeños relevantes para una proforma de una obra civil pueden variar según el proyecto y deben ser cuidadosamente seleccionados para garantizar una evaluación efectiva y precisa de las soluciones candidatas.

Los algoritmos genéticos mejoran eficiencia, reducen costos y optimizan recursos en la planificación de proyectos de construcción.

Resultados

Lo primero que se está realizando es la búsqueda exhaustiva de la literatura y documentos relacionados con el tema. Partiendo de la base teórica en PMBOK y con la Construction Extension to the PMBOK Guide, se considera la incorporación de un metaanálisis como parte integral de la estrategia de investigación para analizar y sintetizar los resultados de los estudios previos relacionados con la optimización multiobjetivo de tiempo-costo-calidad en proyectos de construcción mediante algoritmo genético [3], con la cual se podrá obtener una visión más completa de los resultados observados.

Para definir el problema, en primer lugar, se tendrá como objetivo principal el diseño de un algoritmo gené-

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

tico para la minimización de los costos incluyendo los límites de los recursos e identificando las variables relevantes del problema, con esto se podrá crear la función de aptitud que debe ser capaz de medir la certeza de una proforma al satisfacer los objetivos de reducción de los costos, para poder entrenar al algoritmo se integrará una población inicial que se puede incluir con una variedad de proformas generados con anterioridad.

Para comprender como se integra los algoritmos genéticos en el establecimiento de proformas, a modo ejemplo, supongamos que tenemos una actividad (A) de colocación de acero en un proyecto de construcción, con valor planeado total (VP_T) de \$1,126,479.01, si tomamos un valor de tiempo de ejecución ($t1$), supongamos que el mes de marzo 2015, el valor planeado a marzo 2015 es de \$410, 098.18 que representa el 36.41 % de ejecución, pero se tiene un valor ganado de \$251, 317.47, es decir, el 22.31 % de avance en la obra por lo tanto se tiene un retraso del 14.10 %.

Nuevamente supomgamos que para el siguiente trimestre se requiere un avance del 67.85 % en la actividad, aquí es donde se establece una proforma para lograr llegar a este objetivo, asignando más recurso a la actividad, o bien, aumentado el tiempo para terminarla.

Para poder ejecutar la actividad se le asignan recursos (materiales (a), mano de obra (b), maquinaria (c), fletes (d), herramienta (e), subcontratos (f), costos indirectos (g) y otros (h)), que están determinados en valor monetario generando un costo por esta actividad, los cuales podemos ver como variables o genes, por lo tanto cualquier posible solución es un conjunto de recursos que en la actividad, $A = a,b,c,d,e,f,g,h$ entonces la suma de los recursos es $\varnothing((abcdefgh)) = 67{,}85\,\%$, siendo $\varnothing$ la función de adaptación.

La **inicialización** es crear una población inicial de soluciones o individuos (i), en el ejemplo se requiere llegar al 67.85 % de avance en la obra por lo que iniciamos con una población inicial de 4 individuos, se indica Δ el incremento de recurso para llegar al avance que la función de adaptación indique:

$$i_1 =< \Delta abcd\Delta efgh >, \varnothing(i_1) = 52{,}80\,\%$$
$$i_2 =< a\Delta bcde\Delta fgh >, \varnothing(i_2) = 48{,}65\,\%$$
$$i_3 =< ab\Delta cdef\Delta gh >, \varnothing(i_3) = 39{,}70\,\%$$
$$i_4 =< abc\Delta defg\Delta h >, \varnothing(i_4) = 65{,}50\,\%$$

Se realiza una **selección** por torneo con un tamaño de dos individuos denominados padres (p) en forma aleatoria se crean 4 torneos quedando de la siguiente manera (i1, i4), (i2, i1), (i3, i2), (i2, i4) y. con la función ganador(ix, iy) se selecciona el más apto quedando de la siguiente manera:

$$p_1 = ganador(i_1, i_4) = i_4 < abc\Delta defg\Delta h >$$
$$p_2 = ganador(i_2, i_1) = i_1 < \Delta abcd\Delta efgh >$$
$$p_3 = ganador(i_3, i_2) = i_2 < a\Delta bcde\Delta fgh >$$
$$p_4 = ganador(i_2, i_4) = i_4 < abc\Delta defg\Delta h >$$

En la **combinación** de los padres seleccionados $p[_1$, p_2, p_3, p_4 se realiza un cruce de individuos a partir de un número aleatorio de 1 a $n-1$ genes, en este ejemplo del 1 al 7. Para la combinación tomamos parejas de padres de la siguiente manera $(p1, p3)$, $(p2, p4)$, por ejemplo, para la primera pareja tomamos un valor de 3 y para la segunda pareja un valor de 5 quedando la descendencia de hijos (h) de la siguiente forma:

$$h_1 = (abcde\Delta fgh) = 45{,}89\,\%$$
$$h_2 = (a\Delta bc\Delta defg\Delta h) = 66{,}70\,\%$$
$$h_3 = (\Delta abcd\Delta efg\Delta h) = 65{,}98\,\%$$
$$h_4 = (abc\Delta defgh) = 32{,}65\,\%$$

La mutación de los hijos h_1, h_2, h_3, h_4, se realizan cambios aleatorios de los genes de la cadena del individuo con la finalidad de introducir variabilidad en la población de soluciones para explorar nuevas posibilidades y evitar la convergencia prematura hacia óptimos locales. A continuación, a manera de ejemplo, se hacen los siguientes cambios, en el gen de incremento:

$$(f \leftharpoons henh_1); (b \leftharpoons eenh_2); (a \leftharpoons cenh_3); (d \leftharpoons genh_4)$$

Entonces las mutaciones quedan de la siguiente manera:

$$m_1 = (abcdefg\Delta h) = 48{,}59\,\%$$
$$m_2 = (abc\Delta d\Delta efg\Delta h) = 67{,}70\,\%$$
$$m_3 = (ab\Delta cd\Delta efg\Delta h) = 47{,}98\,\%$$
$$m_4 = (abcdef\Delta gh) = 20{,}65\,\%$$

De esta forma se hace una evaluación de todos los individuos utilizando una función de aptitud, seleccionando las mejores soluciones, este proceso se repite un número fijo de generaciones o bien hasta que se cumpla el criterio de optimización. Una vez que el algoritmo ha convergido o ha alcanzado un límite de tiempo, se devuelve la mejor solución encontrada hasta el momento como el resultado del algoritmo genético.

Estos resultados son hipotéticos dado que se asume que a mayores recursos se obtiene un mayor avance, el objetivo es dar un acercamiento a lo que será el diseño del algoritmo genético para el establecimiento de proformas.

Conclusiones

El algoritmo genético propuesto puede ser una herramienta útil para establecer proformas en proyectos de construcción de manera eficiente y precisa. Sin embargo, se requiere una base de datos confiable y completa de proyectos similares previamente ejecutados para la evaluación de la aptitud de las proformas. Además, es necesario realizar pruebas y ajustes en el algoritmo para adaptarlo a las particularidades de cada proyecto de construcción específico. La introducción de algoritmos

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

genéticos en la elaboración de proformas en proyectos de construcción ofrece una oportunidad para mejorar la eficiencia en la planificación y la toma de decisiones. Estos algoritmos pueden optimizar la asignación de recursos y el tiempo para cumplir con los objetivos del proyecto.

No existe una única solución a este problema por lo que la investigación se centrará en diseñar un algoritmo genético que pueda asistir al personal de control de proyectos en la toma de decisiones al momento de la elaboración de proformas y mejorar la planificación y estimación de costos en proyectos de construcción. Además, al reducir el tiempo y los recursos necesarios para generar proformas, se pueden mejorar la eficiencia y la rentabilidad de este proceso en proyectos de construcción.✷

REFERENCIAS

1. Urgilés, P., Claver, J., Miguel, S. (2018). Análisis de las técnicas del cronograma valorado y valor ganado para el seguimiento y control de proyectos de construcción complejos. *International Congress on Project Management and Engineering*. Madrid: Creative Commons.
2. Institute, P. M. (2017). Construction Extension To The PMBOK. Project Management Institute.
3. Isikyildiz, S. y Akcay, C. (2020). Multi-objective optimization of time-cost-quality in construction projects using genetic algorithm. *Revista de la Construcción*, 19(3).
4. Carmona, E.J. y Severino, F.G. (2021). Fundamentos de computación evolutiva. Marcombo.
5. Gil-Velazquez, L., Sil-Acosta, M., Domiguez-Sanchez, Torres-Arreola, E. y LDP Medina Chavez, J. (2013). Diagnóstico y tratamiento de la diabetes mellitus tipo 2. *Rev Med Inst Mex Seguro Soc.*, 1–16.
6. Banihashemi, S., Khalili, S., Sheikhkhoshkar, M. y Fazeli, A. (2022). Machine learning-integrated 5D BIM informatics: building materials costs costs data classification and prototype development. Innovative Infrastructure Solutions, 7(215).
7. Urgilés, P., Claver, J., Miguel Angel, S. (2018). Análisis de las técnicas del cronograma valorado y valor ganado para el seguimiento y control de proyectos de construcción complejos. *International Congress on Project Management and Engineering. Madrid*: Creative Commons.
8. González, J., Solís, R. y Alcudia, C. (2010). Diagnóstico sobre la Planeación y Control de Proyectos en las PYMES de Construcción. Revista de la Construcción, 9(1), 17 - 25.
9. Jiménez, F.C. y Castro Corrales, J.E. (2013). Implementación De Algoritmos Genéticos Para La Optimización De Un Presupuesto De Obra De Una Vivienda En Bogotá. Dc. Trabajo de Grado.
10. Lledó, P., 2017. Director de proyectos: Cómo aprobar el examen PMP sin morir en el intento. 6ta ed, Estados Unidos.

SOBRE LOS AUTORES



José Manuel Pérez Esquivel es Ingeniero en computación con 14 años de experiencia como Analista Programador. Sus intereses de investigación incluyen el desarrollo de sistemas inteligentes en la gestión de proyectos para la ingeniería civil y en el desarrollo de complementos en aplicaciones para la automatización de procesos en la metodología Building Information Modeling (BIM). Actualmente, está cursando una Maestría en Ciencias de la Computación en el Centro Universitario UAEM Valle de Chalco con una línea de investigación en Inteligencia Artificial (IA).



Cristina Juárez Landín es Profesora de tiempo completo en la Universidad Autónoma del Estado de México, adscrita al Centro Universitario Valle de Chalco y ha coordinado diversos programas educativos: Ingeniería en Computación, Informática Administrativa, Maestría y Doctorado en Ciencias de la Computación. Es miembro del Cuerpo Académico de Cómputo Inteligente y Sistemas y cuenta con perfil PRODEP, así también, pertenece al Sistema Nacional de Investigadores. Sus líneas de investigación son sistemas inteligentes con aplicación en los ámbitos social, educativo y médico, así como, procesamiento de señales e imágenes, temáticas en las cuales ha realizado publicaciones nacionales e internacionales.



Marco Alberto Mendoza Pérez es Profesor de Tiempo Completo, investigador, docente de Ingeniería en Computación, Maestría y Doctorado en Ciencias de la Computación, y responsable del Laboratorio de Electrónica en la Universidad Autónoma del Estado de México (UAEMex)/Centro Universitario Valle de Chalco. Miembro del Sistema Nacional de Investigadores (SNI) del Consejo Nacional de Humanidades Ciencias y Tecnologías (CONAHCYT). Sus áreas de interés son la robótica, la realidad aumentada y la inteligencia artificial en la educación.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

La inteligencia artificial como apoyo en la identificación de ideación suicida en comentarios de texto en español

J. Patricia Sánchez-Solis, Diana Irasema Cervantes Arreola, Ana Brito Sosa, Gilberto Rivera y Rogelio Florencia

Hasta el día de hoy, el suicidio es un problema social que no se ha logrado abordar en su totalidad para su prevención. En particular, de acuerdo con los datos recabados por el Instituto Nacional de Estadística y Geografía durante el periodo comprendido entre 1994 y 2022 [1], México refleja en las estadísticas de mortalidad que el suicidio va en aumento.

A lo largo de los años la Psicología ha tratado el suicidio como un tema delicado que representa un problema de salud pública, ya que no solo se pierde una vida, sino que también impacta en los vínculos afectivos y sociales de los familiares. Algunas personas que presentan conductas suicidas no desean morir, solo quieren dejar de sufrir [2]. Esta conducta se puede ver influenciada por ciertos factores de riesgo que se relacionan con la persona en cuestión y el grupo social al que pertenece. Entre los factores que se pueden identificar se encuentran: edad, sexo, estado civil, situación económica y laboral, creencias religiosas, conductas suicidas por herencia familiar y antecedentes de conductas autolesivas, distintos tipos de trastornos, esquizofrenia, abuso de sustancias adictivas, salud física, capacidad para resolver problemas, desesperanza, agresividad, entre otros [3].

La Organización Mundial de la Salud afirma que cada 40 segundos ocurre un suicidio [1]. En la actualidad se busca predecir las conductas suicidas para prevenir pérdidas humanas [4]. Para esto se requiere identificar con anticipación señales que muestren una conducta suicida. Las personas que han cometido suicido han dejado evidencias de su actuar en distintos medios de comunicación tales como redes sociales y/o cartas [5] para expresar sus emociones y sentimientos de forma libre. Es por esto que actualmente las redes sociales se pueden considerar como una herramienta potencial para la identificación de personas con ideación suicida.

Sin embargo, debido al aumento de usuarios en estas plataformas se han generado demasiados comentarios dificultando su monitoreo manual. Analizar de forma automatizada los mensajes podría ayudar a identificar y prevenir el suicidio de manera anticipada, así, las personas afectadas podrían ser dirigidas hacía instituciones que les brinden apoyo psicológico [6].

Considerando lo antes mencionado, los científicos han creado una línea de investigación para el análisis de datos permitiendo procesar la información mediante diferentes algoritmos de aprendizaje automático.

Con el uso de estos algoritmos se pretende identificar la ideación suicida en los comentarios que las personas dejan en redes sociales. La finalidad es que estas herramientas se puedan incorporar en dichas plataformas a futuro y sirvan de apoyo para la prevención del suicidio. Esto como primera alerta para familiares, instituciones y autoridades, entre otros. Sin embargo, existen pocas investigaciones en donde se hayan utilizado comentarios de texto en español para abordar el suicidio, razón que motiva el presente trabajo. Se implementaron algoritmos de aprendizaje automático, en particular de clasificación, para identificar la ideación suicida en comentarios de texto recolectados de distintos medios de comunicación.

Trabajos relacionados

En esta sección se describirán algunos trabajos de investigadores que han abordado el tema de la prevención del suicidio utilizando técnicas de aprendizaje automático.

En la investigación realizada por Schoene y Dethlefs [5], se identificaron notas suicidas aplicando varios clasificadores con base en tres tipos de comentarios: suicidas, depresivos y amor. El algoritmo que mostró la mejor exactitud fue *Logistic Model Tree* al obtener un 86.61 % en el reconocimiento de notas suicidas.

Por otro lado, en el trabajo realizado por Birjali et al. [4] se recabaron 842 tweets, para determinar si los usuarios corrían el riesgo de cometer suicidio. La clasificación se realizó aplicando distintos algoritmos de aprendizaje automático siendo *Sequential Minimal Optimization* el que obtuvo 89.5 % de precisión respecto a tweets que presentaban riesgo de suicidio.

Materiales y métodos

Este trabajo inició con la creación de un conjunto de datos que incluyera tanto comentarios con ideación suicida como también aquellos que no presentaran dicha característica. Los comentarios recolectados fueron clasificados manualmente por un profesional en psicología. Los que mostraron tendencia suicida fueron identificados como la clase *suicida* (1 o positiva); y como clase *no suicida* (0 o negativa) aquellas notas que aluden a un sentido metafórico o de expresión de melancolía, pero no de ideación

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

suicida. Para crear la clase *no suicida*, también se incluyeron comentarios que mostraron un sentimiento depresivo. Esto debido a que se consideró que dicha emoción se puede llegar a confundir con un intento de suicidio. En la Figura 1 se muestran las etapas del suicidio. Los datos recolectados fueron revisados para eliminar información o datos redundantes como nombres propios, descripciones, entre otros aspectos que no eran importantes.

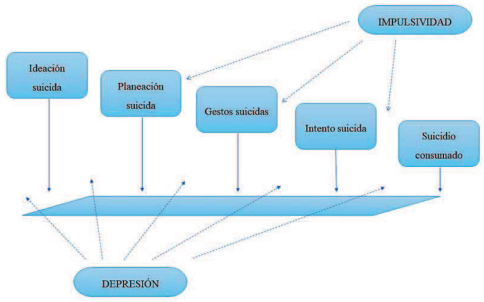


Figura 1. . Espectro de las etapas del suicidio. Tomado de [7].

Se realizaron varias búsquedas en distintos medios de comunicación, tales como: redes sociales, blogs de psicología, cartas de personas que cometieron suicidio, encuestas y notas periodísticas.

En la primera búsqueda se logró obtener un conjunto de datos compuesto por 110 notas. Se depuraron manualmente y fueron clasificados por el experto en psicología. Se obtuvieron 106 frases con ideación suicida y 4 frases que no presentan dicha tendencia.

La segunda recolección de datos se realizó en sitios web de prevención de suicidio, blogs y notas periodísticas. Se obtuvieron 169 comentarios nuevos para enriquecer el conjunto de datos de los cuales 130 corresponde a frases sin evidencia y 39 frases con tendencia suicida.

Además, para obtener frases auténticas de pacientes que presentaron pensamientos suicidas fue necesario contactar a instituciones especializadas en el área de psicología del estado de Chihuahua. Se logró la colaboración voluntaria de las siguientes instituciones:

- Casa Amiga Esther Chávez Cano
- Centro Integral de Salud Mental
- Centro de Protección de Mujer a Mujer
- Centro de terapia familiar, individual y de pareja
- Centro Familiar Psicológico

Se solicitó a los especialistas de estas instituciones contestar una encuesta en línea. Participaron 15 psicólogos quienes proporcionaron 51 frases que generalmente escriben o mencionan los pacientes que han presentado pensamientos o ideación suicida.

Los algoritmos de aprendizaje automático son capaces de detectar ideación suicida en comentarios escritos en español.

Por último, se adquirieron 62 comentarios de blogs con temáticas de depresión. Se realizó esta tarea con el fin de equilibrar el número de comentarios en las dos clases: *suicida* y *no suicida*. Esto se realizó debido a que los algoritmos han mostrado un mejor desempeño cuando el conjunto de datos tiene la misma cantidad de elementos en cada clase. En total se recabaron 392 comentarios, de los cuales 196 pertenecen a la clase *suicida* y 196 a la *no suicida*.

Posterior a la recolección de los datos se hizo una limpieza de éstos con el fin de mejorar su calidad para lo cual se realizaron las siguientes acciones:

- eliminar signos de puntuación,
- cambiar las palabras a minúsculas,
- remover números, saltos de línea, tildes y tabuladores,
- separar el texto en palabras según los espacios en blanco que este contenga, y
- convertir cada palabra a lexema.

Después, los comentarios fueron analizados utilizando las herramientas *wordcloud* que permite identificar las palabras más importantes en un texto y *stopwords* que remueve palabras tales como pronombres, conectores y artículos, que no aportan un significado a la investigación. En la Figura 2 se muestran las palabras más relevantes del conjunto de datos creado que se identificaron con *wordcloud*.



Figura 2. Palabras más importantes del conjunto de datos.

Los comentarios escritos en los distintos medios de comunicación pueden ser utilizados para la detección temprana de la ideación suicida.

Los algoritmos de clasificación utilizados en este trabajo fueron: *Random Forest* (*RF*), *Support Vector Machine* (*SVM*), *Naive Bayes* (*NB*) y *k-Nearest-Neighbors* (*k-NN*). Los resultados de estos algoritmos se compararon con el objetivo de conocer cuál de ellos obtiene el mejor desempeño al identificar comentarios en español que presentan ideación suicida.

Para que los algoritmos puedan procesar los comentarios y clasificarlos se requiere que los textos se representen en forma de vectores numéricos. Esto se llevó a cabo aplicando dos técnicas utilizadas en el procesamiento de lenguaje natural: *Term Frequency-Inverse Document Frequency* (*TF-IDF*) y *CountVectorizer*. Estas herramientas se utilizaron con el objetivo de identificar cuál de ellas logra los mejores resultados. La diferencia entre estas dos técnicas radica en la importancia que se le da a la frecuencia con la que aparecen las palabras en el conjunto de datos.

El desempeño de los clasificadores se obtuvo utilizando la técnica de validación cruzada, la cual divide el conjunto de datos en varios subconjuntos. Esto se realiza para que el algoritmo pueda ser evaluado en múltiples subconjuntos de datos, obteniendo así una medida más confiable del rendimiento general del mismo. En la evaluación también se aplicaron algunas de las métricas usadas comúnmente en los algoritmos de clasificación: *exactitud*, *sensibilidad* y *especificidad*.

El proceso de clasificación de los comentarios realizado por cada algoritmo se desarrolló de la siguiente manera: el conjunto de datos (comentarios) es leído por el algoritmo. Una parte de los comentarios es utilizada para que el algoritmo aprenda cuáles tienen ideación suicida y cuáles no. Una vez que termina la etapa de aprendizaje, la otra parte de los comentarios se utiliza para que el algoritmo los clasifique y determine a qué clase pertenece cada uno. Esto para conocer qué porcentaje de aciertos logra el algoritmo, porque de antemano se conoce a qué clase pertenece cada comentario.

Resultados y Discusiones

A continuación, se presentan los resultados promedio de cada métrica resaltando en color negro los mejores valores obtenidos.

Los mejores resultados se alcanzaron al usar la técnica *TF-IDF*.

En la Tabla 1 se puede observar que el algoritmo con mejor desempeño fue *NB* ya que obtuvo un 82.17 % de *exactitud*. Esta métrica mide la proporción de los comentarios clasificados correctamente por el algoritmo (tanto *suicidas* como *no suicidas*) con respecto al número total de estos, dando una idea general de su rendimiento.

En la Tabla 2 se puede ver que el algoritmo *NB* obtuvo el mejor valor: un 95.92 % en *sensibilidad*, métrica que determina cuántos de los comentarios *suicidas* reales fueron clasificados correctamente por el algoritmo. Mientras que *SVM* logró el mejor desempeño en *especificidad* ya que obtuvo un 74.91 %. Esta métrica determina la cantidad de comentarios *no suicidas* reales que fueron clasificados correctamente por el algoritmo.

Tabla 1. Exactitud promedio de los clasificadores

Clasificador	**CountVectorizer**	**TF-IDF**
NB	**81.40 %**	**82.17 %**
k-NN	61.98 %	62.97 %
RF	72.95 %	72.17 %
SVM	78.87 %	73.74 %

Tabla 2. Sensibilidad y Especificidad promedio de los clasificadores

Clasificador	Métrica	CountVectorizer	TF-IDF
NB	Sensibilidad	95.42 %	95.92 %
	Especificidad	67.35 %	68.36 %
k-NN	Sensibilidad	63.25 %	52.42 %
	Especificidad	60.62 %	73.39 %
RF	Sensibilidad	89.30 %	87.78 %
	Especificidad	56.55 %	56.47 %
SVM	Sensibilidad	88.74 %	72.30 %
	Especificidad	68.27 %	74.91 %

Conclusiones

El tema de la prevención del suicidio aún tiene mucho camino por recorrer. En esta investigación se mostró que las técnicas de procesamiento de lenguaje natural y los algoritmos de clasificación son herramientas útiles para identificar comentarios que manifiestan ideación suicida.

Estos algoritmos pueden ser integrados en cierto tipo de aplicaciones que permitan alertar a familiares o incluso a especialistas sobre un posible caso de suicidio de alguna persona cercana a ellos.

Con base en los resultados obtenidos, se puede concluir que la combinación del algoritmo *NB* con la técnica de *TF-IDF* obtuvo los mejores resultados al identificar comentarios con ideación suicida. Sin embargo, se requiere continuar con investigaciones más profundas en donde se incremente el conjunto de datos, así como también se considere la presencia de emociones y su intensidad para predecir el suicidio.✷

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

REFERENCIAS

1. INEGI. (2022). Suicidios registrados (Defunciones registradas), Estados Unidos Mexicanos, 2022. Recuperado el 31 de julio de 2023, de https://www.inegi.org.mx/app/indicadores/?ind=6200240338&tm=6#D6200240338.
2. Echeburúa, E. (2015. Las múltiples caras del suicidio en la clínica psicológica. *Terapia psicológica*, 33, 117—126.
3. Bobes, J. (2011). Suicidio y psiquiatría: recomendaciones preventivas y de manejo del comportamiento suicida. *Triacastela*, ISBN:9788495840592, 8495840596, 188.
4. Birjali, M., Beni-Hssane, A., Erritali, M. (2017). Machine Learning and Semantic Sentiment Analysis based Algorithms for Suicide Sentiment Prediction in Social Networks. *Procedia Computer Science*, 113, 65-72.
5. Schoene, A. M. y Dethlefs, N. (2016). Automatic Identification of Suicide Notes from Linguistic and Sentiment Features. En *Proceedings of the 10th SIGHUM workshop on language technology for cultural heritage, social sciences, and humanities*. Alemania, 128-133.
6. Desmet, B. y Hoste, V. (2013). Emotion detection in suicide notes. *Expert Systems with Applications*, 40, 6351–6358.
7. Rivera, M. E. (2009). Psicología y comunicación visual: estrategias para la prevención del suicidio en adolescentes, México, Trillas, 208.

SOBRE LOS AUTORES



J. Patricia Sánchez-Solis recibió el título de Doctora en Ciencias de la Computación por parte del Tecnológico Nacional de México (Instituto Tecnológico de Tijuana) en 2017. Actualmente es profesora-investigadora adscrita al Departamento de Ingeniería Eléctrica y Computación de la Universidad Autónoma de Ciudad Juárez. Es miembro del Sistema Nacional de Investigadores (SNI 1) y vicepresidente de Eurekas Community. Entre sus áreas de interés se encuentran el aprendizaje automático, la optimización multiobjetivo, las metaheurísticas evolutivas, y el procesamiento de datos masivos.



Diana Irasema Cervantes Arreola recibió el título de Doctora en Psicología por parte de la Universidad de Guadalajara en el año 2017. Es profesora Investigadora de Tiempo Completo en la Universidad Autónoma de Ciudad Juárez, en el Departamento de Humanidades. Es miembro del Sistema Nacional de Investigadores (SNI 1), así como miembro de la Red de Investigadores del Estado de Chihuahua (REDIECH). Entre sus líneas de investigación se encuentran: aptitudes sobresalientes y talento en jóvenes y talento docente, habilidades socioemocionales y procesos de enseñanza y aprendizaje.



Ana Karen Brito Sosa recibió el título de Ingeniero en Sistemas Computacionales en la Universidad Autónoma de Ciudad Juárez en 2021, con el proyecto de investigación llamado “Identificación de ideación suicida en comentarios de texto utilizando algoritmos de aprendizaje automático”. Actualmente se encuentra laborando como Técnico de Pruebas en la empresa Foxconn, ubicada en Cd. Juárez, Chihuahua.



Gilberto Rivera recibió el grado de Doctor en Ciencias en Computación por parte del Tecnológico Nacional de México (Instituto Tecnológico de Tijuana), siendo su tesis doctoral la ganadora en el certamen nacional de tesis de la Sociedad Mexicana de Inteligencia Artificial. Actualmente, es profesor de tiempo completo en la Universidad Autónoma de Ciudad Juárez. Además, es actual miembro del Sistema Nacional de Investigadores (SNI 1) y vicepresidente de Eurekas Community. Sus intereses en investigación se centran en el apoyo a la decisión con múltiples criterios, la optimización con muchas funciones objetivo, y las metaheurísticas evolutivas y de inteligencia de enjambre.



Rogelio Florencia recibió el grado de Doctor en Ciencias en Computación por el Tecnológico Nacional de México (Instituto Tecnológico de Tijuana) en 2016. Desde 2016 es profesor de tiempo completo en la Universidad Autónoma de Ciudad Juárez, México. Actualmente es miembro del Sistema Nacional de Investigadores (SNI 1). Sus intereses de investigación se encuentran en las áreas de procesamiento del lenguaje natural, aprendizaje automático y representación del conocimiento.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

ARTÍCULO ACEPTADO

Dispositivo de navegación para personas ciegas basado en algoritmos de búsqueda

Yareni Cervantes Villalba, Marco Antonio Aguilar Cortés, Jacobo Robles Calderón y Guadalupe Robles Calderón

Introducción

A lo largo de la historia, diversas causas han generado problemas visuales y ceguera en un número significativo de personas. La Organización Mundial de la Salud identifica enfermedades como cataratas, degeneración muscular, glaucoma, retinopatía diabética, infecciones oculares, tracoma y deficiencia de vitamina A como principales causas de ceguera a nivel mundial, afectando a 253 millones de personas con discapacidad visual, incluyendo 36 millones de ciegos totales [1]. La discapacidad visual actualmente presenta dificultades importantes, como limitaciones en el desplazamiento y la independencia de las personas. En México, se estima que alrededor de 2.7 millones de personas tienen dificultades de visión, colocándola en segundo lugar dentro de las discapacidades en el país [2]. El rápido crecimiento urbano ha impactado la movilidad de personas ciegas debido a la falta de infraestructuras accesibles. Sin embargo, se han desarrollado herramientas tecnológicas para mejorar su calidad de vida y promover la inclusión social, lo que ha impulsado avances relevantes en el apoyo al desplazamiento de personas ciegas como un elemento clave en el progreso social.

Dentro de dichos avances, existe una investigación que hace referencia a un sistema compuesto por sensores ultrasónicos, zumbadores y un microcontrolador para detectar obstáculos a aproximadamente un metro de distancia, brindando información al usuario a través de los zumbadores. También se integró un sensor para detectar hoyos en el suelo. Según las pruebas, el dispositivo tuvo una efectividad del 90.1 %, superando el uso del bastón blanco clásico en la detección de obstáculos [3].

Otro avance hace uso de los teléfonos inteligentes, en el cual se ha diseñado un sistema de software que combina los métodos de localización y la interfaz hombre-máquina, de manera eficiente para cumplir con las necesidades de desplazamiento de personas con problemas visuales [4].

Una propuesta más es la de un sistema de navegación en tiempo real que utiliza sensores, una placa de procesamiento, una interfaz de usuario y lógica difusa. La comunicación con el sistema se realiza a través de voz. El sistema incluye un controlador ROS, unos anteojos con 3 sensores ultrasónicos y módulos vibradores para detectar obstáculos y objetos, y un accesorio de mano con un sensor ultrasónico y un mini-LiDAR [5].

Tomando en cuenta el uso de bastones blancos se ha diseñado un prototipo de navegación, el cual es utilizado por la mayoría de las personas con problemas de visión. Dicho prototipo puede guiar de manera automática al usuario haciendo vibrar el mango del bastón [6].

Otra alternativa al uso de bastones blancos es aquella que es capaz de realizar reconocimiento de códigos de color con el fin de poder seguir rutas preestablecidas de manera segura, lo cual permite al usuario desplazarse con mayor confianza dentro de determinadas áreas mediante señales táctiles de advertencia [7].

A diferencia de otras herramientas que detectan cambios en el suelo u obstáculos, este sistema se enfoca en proporcionar rutas seguras entre la ubicación actual y el destino del usuario, especialmente en entornos desconocidos o poco familiares. Además, de notificar sobre peligros como escaleras y rampas, se busca mejorar la seguridad y la experiencia de desplazamiento para personas con discapacidad visual.

Construcción del Prototipo

Después de llevar a cabo un análisis comparativo entre distintos componentes electrónicos, se decidió utilizar un controlador ESP32 y un sensor de color TCS34725. Después de ensamblar la placa con componentes electrónicos, se diseñó un contenedor para alojar el circuito y dos baterías AA recargables. También se creó un soporte personalizado para montar el sensor de colores en la parte inferior del bastón. El sensor identificará líneas de color y ofrecerá retroalimentación sobre la dirección correcta. La figura 1 muestra el bastón con los módulos integrados.



Figura 1. Prototipo final del sistema de desplazamiento.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

En México, la dificultad para ver, incluso usando lentes, es la segunda discapacidad que más afecta a la población.

Codificación de la Aplicación Móvil

El desarrollo del software para recibir alertas del prototipo y compartir la ubicación de origen y destino, se realizó mediante la programación de una aplicación móvil utilizando el Framework de React Native y el lenguaje de programación TypeScript. También se implementaron algoritmos para calcular la ruta óptima hacia destinos específicos. Es fundamental mencionar que se requiere la previa identificación de los destinos de interés del usuario del bastón, para que el algoritmo de Dijkstra pueda proporcionar la ruta más rápida y eficiente.

Algoritmo de Búsqueda

La navegación de rutas preestablecidas se logró mediante el algoritmo de Dijkstra, que encuentra el camino más corto minimizando la distancia entre dos puntos. Se diseñó un grafo con 17 nodos interconectados para representar las rutas y conexiones entre lugares estratégicos, facilitando la navegación. La figura 2 hace referencia al grafo.

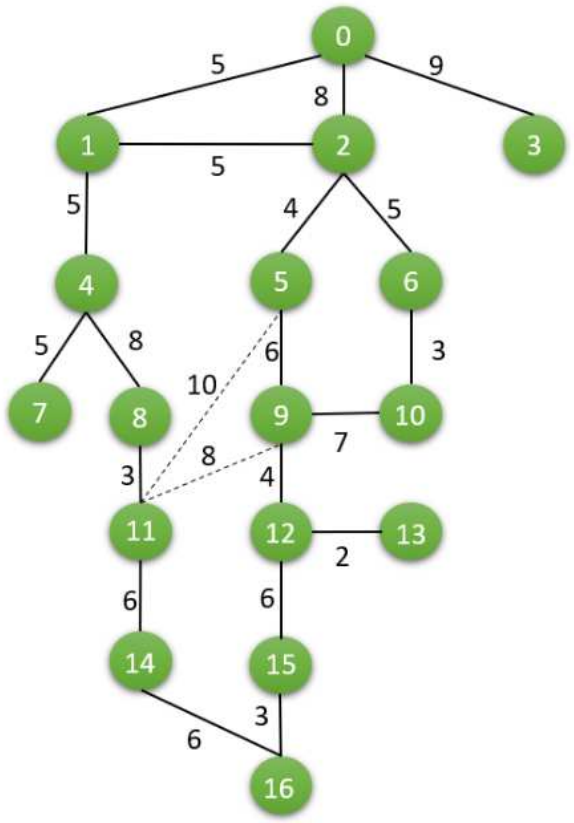


Figura 2. Grafo propuesto para pruebas.

Se eligió un grafo no dirigido debido al desplazamiento en ambas direcciones, y se optó por un grafo ponderado con costos positivos para cumplir con los requisitos necesarios para el algoritmo de Dijkstra. A partir del grafo G propuesto, se creó una matriz de adyacencia, ajustando los valores de 0 a ∞ en lugares donde no existían relaciones entre vértices.

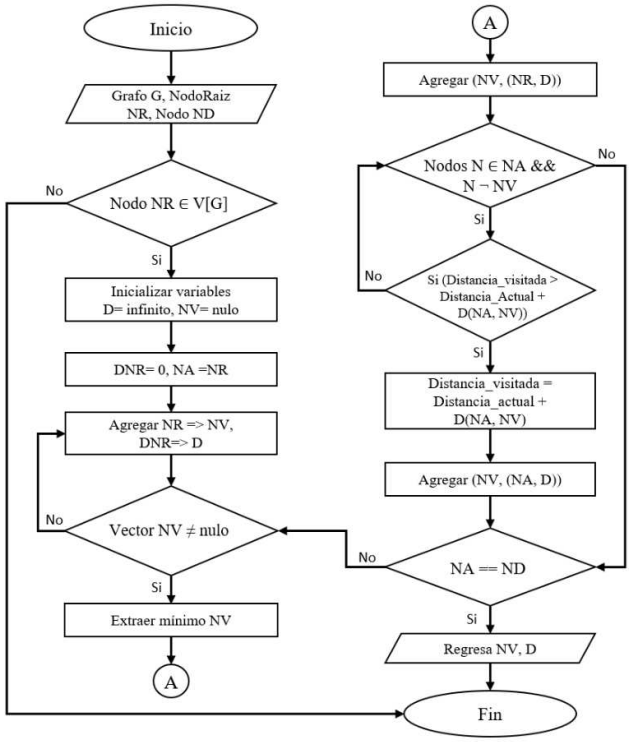


Figura 3. Diagrama de flujo para determinar la ruta más corta.

A partir de la definición e inicialización de las variables, la ejecución del algoritmo se detalla a continuación:

- Sea el nodo actual NA = NR
- Se recorre los nodos adyacentes a NA a excepción de los nodos que ya han sido visitados NV
- Si la distancia del nodo raíz NR hasta el nodo visitado NV guardada en el vector D es mayor que la distancia existente entre el nodo raíz NR y el nodo actual NA sumada a la distancia de NA hasta NV, ésta se sustituye por la segunda mencionada, la cual resulta ser la más corta.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

- El nodo actual explorado es marcado como nodo visitado NV.
- Selección del nodo actual: El siguiente nodo para utilizar como NA, será aquel con menor valor dentro vector D, también conocido como la cola de prioridad, determinado el nodo actual, se vuelve a realizar la exploración de nodos.

Resultados y Discusión

Tras completar el desarrollo de la aplicación y finalizar el circuito electrónico, se llevaron a cabo pruebas exhaustivas para evaluar su funcionamiento. Se enfocó especialmente en evaluar el reconocimiento de color para asegurar que los datos mostrados en la aplicación fueran precisos y coincidieran con los capturados por el sensor. En caso de detectar información incorrecta, se realizaron las calibraciones y ajustes necesarios para corregir cualquier desviación.

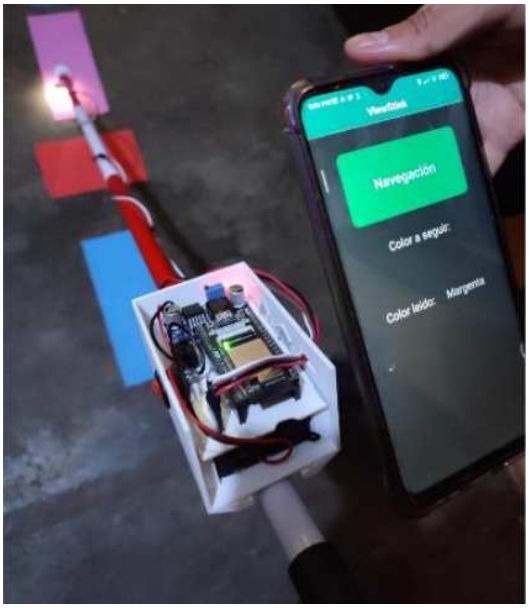


Figura 4. Pruebas de conexión y reconocimiento de color.

Posteriormente, se realizaron pruebas utilizando como referencia el desplazamiento entre dos puntos hipotéticos. El objetivo era confirmar si los resultados obtenidos por el algoritmo coincidían con los resultados obtenidos de forma manual. Para llevar a cabo las pruebas, se seleccionaron los nodos 6 y 14 dentro del grafo propuesto. El nodo 6 fue considerado como punto inicial u origen, mientras que el nodo 14 se estableció como punto final o destino. Se procedió a realizar una comparación manual de todos los posibles caminos existentes entre estos dos puntos, siguiendo la lógica del algoritmo de búsqueda propuesto. La información se muestra en la tabla 1, donde se observan los pesos correspondientes a cada uno de los posibles caminos entre ambos nodos, siendo 24 el menor peso obtenido de manera manual, recorriendo los nodos 6,10,9,11 y 14; seguido del peso 25 recorriendo los nodos 6,2,5,11 y 14.

Tabla 1. Análisis del camino más corto

Análisis de pesos en caminos del 6 al 14									
Camino 1	Nodos	6	2	5	11	14			
	Suma	0	5	9	19	25			
Camino 2	Nodos	6	2	5	9	11	14		
	Suma	0	5	9	15	23	29		
Camino 3	Nodos	6	2	5	9	12	15	16	14
	Suma	0	5	9	15	19	25	28	34
Camino 4	Nodos	6	10	9	11	14			
	Suma	0	3	10	18	24			
Camino 5	Nodos	6	10	9	12	15	16	14	
	Suma	0	3	10	14	20	23	29	

Gracias a esto, fue posible determinar que el camino optimo entre ambos puntos es aquel con los nodos [6,10,9,11,14]. Para corroborar estos resultados se llevó a cabo la navegación dentro de la aplicación. La figura 5 muestra los resultados de ejecutar el algoritmo dentro de la aplicación.



Figura 5. Aplicación móvil mostrando resultado de algoritmo.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Finalmente se realizaron las últimas pruebas del prototipo en un espacio controlado, donde se diseñaron rutas simulando cada uno de los nodos del grafo donde el dispositivo de navegación fue utilizado por personas ciegas pertenecientes a una asociación civil. Siete participantes, cinco hombres y dos mujeres, con edades entre 28 y 60 años, utilizaron el dispositivo en un espacio abierto previamente acondicionado para su uso. A pesar de las dificultades iniciales con respecto a la ubicación acordada, las pruebas se llevaron a cabo con éxito en un nuevo espacio.

La entrevista propuesta se dividió en dos partes importantes para obtener la opinión de los participantes antes y después de utilizar el dispositivo. En la primera fase, se enfocó en conocer la opinión de los participantes sobre el uso de herramientas tecnológicas para personas ciegas y si habían tenido experiencias previas con ellas. Se realizaron una serie de preguntas a cada uno de ellos, y las respuestas fueron grabadas con su consentimiento para su posterior análisis.

Luego, se procedió a las pruebas del dispositivo, donde los participantes realizaron un desplazamiento hipotético desde un punto inicial hasta uno final utilizando hojas de colores colocadas en el suelo para el reconocimiento de color.

Al finalizar las pruebas, se llevó a cabo la segunda fase de la entrevista, en la cual los participantes compartieron sus opiniones acerca del funcionamiento del dispositivo, así como sus comentarios y recomendaciones para mejorar su funcionamiento. En la figura 6, se muestra la finalización de pruebas y entrevista a las personas que utilizaron el dispositivo.



Figura 6. Evaluación por parte de personas invidentes.

Las opiniones de los participantes acerca de la aplicación pueden ser observados a en la figura 7, donde menciona que su uso no les resulta ser un mayor problema ya que resulta fácil de entender y utilizar, pero la respuesta del sistema se encuentra desfasada al realizar el reconocimiento del color, lo que podría causar algunos problemas a la hora de desplazarse de manera independiente.

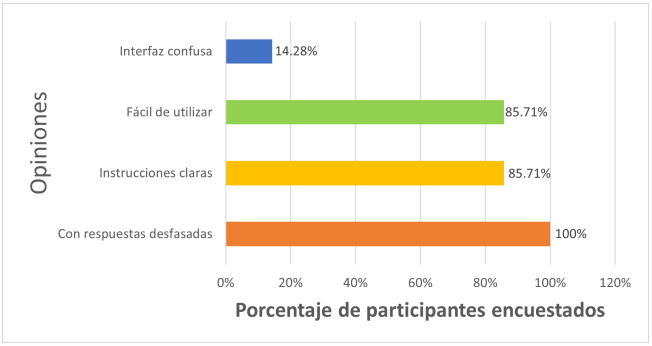


Figura 7. Respuesta de personas que utilizaron el bastón.

Conclusiones

A lo largo de la investigación, se realizaron pruebas que llevaron a mejoras en el sistema propuesto, incluyendo algoritmos de búsqueda para determinar rutas más cortas entre puntos de navegación. Estas rutas resultaron beneficiosas para personas ciegas en lugares complejos o desconocidos, obteniendo buenos resultados.

Aunque la aplicación fue bien recibida por los usuarios, se identificaron algunas observaciones que pueden implementarse en futuras versiones para mejorar su funcionamiento. El uso de voz para mensajes e indicaciones fue destacado como vital para la navegación.

El reconocimiento de colores fue un desafío, con variaciones en las condiciones de iluminación. Se recomienda calibrar los valores de color en el entorno específico y explorar alternativas de reconocimiento para mejorar la velocidad y seguridad.

En general, el sistema recibió una respuesta positiva, sugiriendo que la seguridad y calidad de vida de los usuarios de bastones blancos podrían mejorar. Sin embargo, se enfatiza la importancia de crear entornos seguros y accesibles para todos en las ciudades.✷

REFERENCIAS

1. Steinmetz, J., et al. (2021). Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: the Right to Sight: an analysis for the Global Burden of Disease Study. **The Lancet Global Health**, 9(2), e144-e160.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

2. INEGI. (2021). ESTADÍSTICAS A PROPÓSITO DEL DÍA INTERNACIONAL DE LAS PERSONAS CON DISCAPACIDAD. Comunicado de Prensa Núm. 713/21, 5. Recuperado el 25 de Enero de 2022 de https://www.inegi.org.mx/app/glosario/default.html?p=cpv2020#letraGloP.

3. Yahaya, S., et al. (2019). Development of Obstacle and Pit-Detecting Ultrasonic Walking Stick for the Blind. *FUOYE Journal of Engineering and Technology*, 4(2).

4. Messaoudi, M., Menelas, J. y Mcheick, H. (2020). Autonomous smart white cane navigation system for indoor usage. *Technologies*, 8(3), 37.

5. Bouteraa, Y. (2021). Design and development of a wearable assistive device integrating a fuzzy decision support system for blind and visually impaired people. *Micromachines*, 12(9), 1082.

6. Branig, M. y Engel, C. (2019). Smartcane: an active cane to support blind people through virtual mobility training. En *Proceedings of the 12th ACM International Conference on PErvasive Technologies Related to Assistive Environments*, 327-328.

7. Mocanu, A., et al. (2020). Assistive navigation application for blind people using a white cane embedded system. *IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR)*, 1-5.

SOBRE EL AUTOR



Yareni Cervantes Villa es Ingeniero en Mecatrónica y Maestra en Sistemas Computacionales egresada del Instituto Tecnológico Superior de Teziutlán perteneciente al estado de Puebla. Actualmente se encuentra laborando como desarrollador Web en una consultoría de programación en Ciudad de México. Entre sus intereses se encuentra la Programación, los Sistemas Mecatrónicos y la Robótica de servicio.



Marco Antonio Aguilar Cortés labora en el Tecnológico Nacional de México / Instituto Tecnológico Superior de Teziutlán. Es doctor en Investigación Educativa, Maestro en Sistemas Computacionales y Maestro en Pedagogía. También lleva a cabo actividades de desarrollo de software para instituciones públicas y privadas. Ha sido asesor en eventos académicos regionales y nacionales. Es Perfil Deseable y es miembro de un Cuerpo Académico.



Jacobo Robles Calderón labora en el Tecnológico Nacional de México / Instituto Tecnológico Superior de Teziutlán. Es doctor en Investigación Educativa. Docente investigador con más de 20 años de experiencia a nivel licenciatura, Especialidad y Maestría. Forma parte del cuerpo Académico Calidad y Mejora continua en Servicios Tecnológicos, liderando proyectos de investigación reconocidos y financiados por el Tecnológico Nacional de México, enfocados a la aplicación de TIC en los sectores educativo y empresarial.



Guadalupe Robles Calderón labora en el Tecnológico Nacional de México / Instituto Tecnológico Superior de Teziutlán. Es Licenciada en Informática por el Instituto Tecnológico de Puebla, Maestra en Sistemas Computacionales por la UPAEP y Doctora en Investigación Educativa por la Universidad de Puebla. Ha trabajado en el análisis y diseño de sistemas apoyados de la Ingeniería de Software. Líder y colaboradora de proyectos orientados a la Industria 4.0. Colaboradora en el diseño de Diplomados que apoyan y fomentan la Educación a Distancia del Tecnológico Nacional de México



Imagen tomada de: https://www.nobbot.com/baston-inteligente-discapacidad-visual-navegacion-integrada/.

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

IA & Educación

Yasmín Hernández, Lucía Barrón y Julieta Noguez

Inteligencia artificial generativa en la educación

La llegada de aplicaciones creativas tales como ChatGPT, DALL-E, Bard y CodeWhisperer ha provocado una ola de interés e información en torno a la inteligencia artificial generativa, debido al impacto actual y potencial que tiene en la manera en que llevamos a cabo nuestro trabajo y nuestra vida diaria. La inteligencia artificial generativa (IAG) es una tecnología de inteligencia artificial que genera ideas y contenido a partir de ejemplos, con aplicaciones tan amplias como la generación de imágenes, audio, videos, simulaciones, texto, conversaciones, música y código de programas. El componente clave de la IAG es un modelo generativo que modela la distribución potencial de los datos originales y genera datos similares, con lo que se producen diversas formas de arte, contenido y otros resultados. Los componentes técnicos principales de la IAG son aprendizaje automático, aprendizaje profundo, procesamiento de lenguaje natural (PLN) y procesamiento de imágenes [1].

Los modelos tradicionales de aprendizaje automático se centran en clasificar los puntos de datos, e intentan determinar la relación entre los factores conocidos y desconocidos. Los modelos generativos, en lugar de predecir una etiqueta de acuerdo con algunas características, predicen características de acuerdo con una etiqueta determinada. Por ejemplo, los modelos generativos analizan imágenes de animales para registrar variables tales como formas de orejas, formas de ojos, rasgos de la cola y patrones de piel. Aprenden las características y sus relaciones para comprender cómo son los diferentes animales. Luego, pueden recrear nuevas imágenes de animales que no estaban en el conjunto de entrenamiento [2]. La Figura 1 muestra un esquema general de modelado generativo.

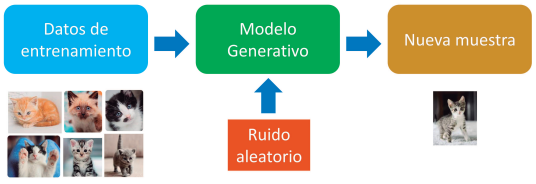


Figura 1. Modelado generativo [3].

En los últimos años, ha habido un interés creciente en la investigación en la aplicación de la IAG en el campo de la educación. Sin embargo, hay un debate abierto sobre los desafíos que presenta para los profesores e investigadores en educación. Algunos consideran que la IAG podría afectar el sistema educativo, mientras que otros la ven como una herramienta que aporta nueva información y como una oportunidad de mejorar la cobertura y la calidad de la educación [1]. A pesar de las preocupaciones y controversias, no hay duda de que el uso de aplicaciones de IAG en ambientes educativos se está convirtiendo en una tendencia de aprendizaje mejorado por tecnología. Varios académicos han señalado el potencial del aprendizaje basado en IAG, por ejemplo, en el fomento de la creatividad, el pensamiento crítico y la capacidad de resolución de problemas de los estudiantes, entre otros [4]. En la Tabla 1 se presentan los diversos roles que desempeña de la IAG en la educación.

Tabla 1. Roles de la IA generativa en la educación [4]

Rol	Tarea
Maestro/Tutor	Proporcionar materiales complementarios o ejemplos Resumir el contenido de aprendizaje Hacer demostraciones
Estudiante/Tutelado	Aprender de los alumnos Realizar tareas, por ejemplo, tareas u obras de arte, siguiendolas solicitudes de los estudiantes
Compañero de aprendizaje	Trabajar como parte de un equipo en tareas de aprendizaje colaborativo
Experto en el dominio	Proporcionar consejos o respuestas a problemas o preguntas particulares
Administrador	Resumir los hallazgos para facilitar la toma de decisiones
Herramienta de aprendizaje	Ayudar a los estudiantes a recopilar y analizar datos Trabajar con los estudiantes Permitir a los estudiantes centrarse en objetivos críticos compartiendo sus cargas de trabajo

Existen varias aplicaciones potenciales del uso de IAG en contextos educativos. Por ejemplo, cuando desempeña el rol de tutor, la IAG puede generar planes de lecciones o corregir la redacción de documentos académicos en cursos de idiomas. Cuando desempeñan el rol de herramienta de investigación/enseñanza, los investigadores o educadores pueden trabajar con IAG para diseñar preguntas para la evaluación o desarrollar rúbricas para evaluar los ensayos de los estudiantes [4].

Con el desarrollo de diversas tecnologías está aumentando la aplicación de la IAG en el campo de la educación, por ejemplo, la popularidad de los dispositivos móviles, el desarrollo de la tecnología de red y las tecnologías de IAG han permitido desarrollar aplicaciones móviles que proporcionan a los estudiantes diversos métodos de aprendizaje y los ayudan a comprender el conocimiento. Un ejemplo es Duolingo, una aplicación gratuita de aprendizaje de idiomas basada en tecnología IAG [1].

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Los ambientes inteligentes de aprendizaje generan cursos personalizados y planes de enseñanza con base en el proceso particular de aprendizaje del estudiante, logrando así una enseñanza personalizada. El sistema puede ajustar automáticamente la dificultad y el contenido del curso en función del rendimiento y el aprendizaje del estudiante, proporcionando tareas de aprendizaje y ejercicios adecuados para el estudiante. Por ejemplo, la plataforma de aprendizaje Knewton utiliza tecnología de IAG para analizar los datos de aprendizaje de los estudiantes para comprender sus necesidades y debilidades de aprendizaje y generar contenidos de cursos personalizados y planes de enseñanza [1].

Los sistemas de calificación inteligente de tareas analizan las tareas de los estudiantes, identifican aciertos y errores, y entregan las calificaciones y sugerencias adecuadas. La plataforma de revisión de tareas de Turnitin utiliza PLN y tecnología de IAG para evaluar las tareas de los estudiantes. Por ejemplo, cuando un estudiante envía una tarea, la plataforma detecta errores gramaticales, errores ortográficos, y plagio, entre otros, a la vez que proporciona sugerencias e ideas de mejora [1].

Los sistemas tutores inteligentes generan contenido y estrategias de enseñanza con base en el análisis de las situaciones de aprendizaje y las necesidades particulares de los estudiantes. Ajustan automáticamente el contenido de la tutoría y los niveles de dificultad en función del rendimiento y el aprendizaje de los estudiantes. Por ejemplo, el sistema tutor inteligente de Yixue Education se basa en IAG para analiza las situaciones de aprendizaje y el desempeño de los estudiantes para generar contenidos y estrategias de tutoría personalizados. Por ejemplo, durante los ejercicios de matemáticas, el sistema determina los niveles de los estudiantes en función de la velocidad y la precisión de las respuestas, y así proporcionar ejercicios y tareas de práctica adecuados [1].

Los sistemas inteligentes de interacción con voz utilizan tecnologías de IAG y de PLN para interactuar con los estudiantes a través de la voz, a fin de comprender mejor sus necesidades y preguntas de aprendizaje. El sistema reconoce el contenido del discurso del estudiante y proporciona respuestas y sugerencias adecuadas. El sistema inteligente de aprendizaje de VIPKID se basa en tecnologías de IAG y de PLN para interactuar con los estudiantes a través de la voz en un curso del idioma inglés. El sistema reconoce la pronunciación y la entonación de los estudiantes entre otras variables [1].

A pesar de que el avance y uso de la IAG han provocado reacciones diversas, las aplicaciones educativas basadas en IAG se han convertido en herramientas importantes en el aprendizaje de los estudiantes, brindando muchos beneficios y oportunidades. La IAG es un recurso que los profesores y estudiantes pueden utilizar para apoyo en la enseñanza y el aprendizaje. Las herramientas actuales de IAG están abriendo nuevos campos de investigación que afectarán la forma en que aprendemos, interactuamos y colaboramos, lo que permitirá brindar a los estudiantes experiencias de aprendizaje personalizadas y más eficientes. Sin embargo, se requieren esfuerzos para abordar los problemas que surgen del uso de la IAG en la educación.✷

REFERENCIAS

1. Yu, H. y Guo, Y. (2022). Generative artificial intelligence empowers educational reform: current status, issues, and prospects. *Front. Educ.*, 8(2022), 1–10.

2. "¿Qué es la IA generativa? - Explicación de la inteligencia artificial generativa - AWS". `https://aws.amazon.com/es/what-is/generative-ai/`. (consultado dic. 04, 2023).

3. "Generative Models: The Next Machine Learning Boom? | by Himanshu Wagh | CodeX | Medium". `https://medium.com/codex/generative-models-the-next-machine-learning-boom-865b80c54fb1`. (consultado dic. 04, 2023).

4. Hwang, G. y Chen, N., Editorial Position Paper: Exploring the Potential of Generative Artificial Intelligence in Education: Applications, Challenges, and Future Research Directions. *Educ. Technol. Soc.*, 26(2).



Imagen tomada de:
`https://universidadducens.edu.mx/blog/importancia-de-la-inteligencia-artificial-generativa-en-la-educacion/`

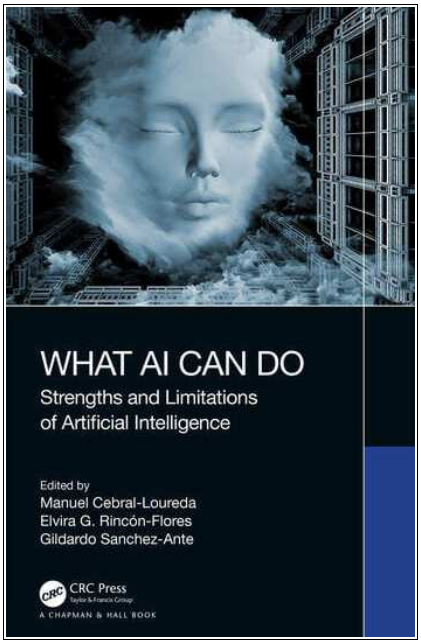
© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Deskubriendo Konocimiento

Alejandro Guerra Hernández y Gildardo Sánchez Ante
deskubriendokonocimiento@komputersapiens.org

Revisión de "What AI Can Do, Strengths and Limitations of Artificial Intelligence" 1st Edition *

Dr. Manuel Cebral-Loureda
Tecnológico de Monterrey
Escuela de Humanidades y Educación



Portada del libro.*

Hay una gran expectativa con lo que puede hacer la IA, más todavía después de la salida de los modelos generativos de IA como chatGPT o Stable Diffusion, entre otros. Pensamos, por ejemplo, en un asistente continuo del ser humano, una especie de consultor, una voz de la conciencia a quien preguntarle y que resuelva todo tipo de dudas. Pero ¿Esto no es antropomorfizar? ¿No es de nuevo darle una categoría humana a aquello que es, precisamente, no humano, no biológico, no orgánico, etc.? Y, sobre todo, ¿no es una forma de subyugar o de subordinar? Normalmente, este planteamiento suele dar respuesta a dos grandes cuestionamientos: (1) ¿puede la IA superar al ser humano, hacerle competencia e incluso amenazarlo intentando obtener su poder?; y, (2) ¿puede la IA perjudicar al ser humano, competir con él, quitándole puestos de trabajo, desde los más mecánicos y repetitivos hasta los más creativos, o empobrecernos personal o socialmente al hacernos perder nuestra capacidad de memoria, o introduciendo sesgos en la información? Desde esta perspectiva de la IA como consultora continua del ser humano, la primera pregunta se responde negativamente, en la medida en que la IA es un producto del ser humano, siempre dependerá de nuestra capacidad para activarla/desactivarla, programarla de un modo o de otro, etc, y, como tal, no puede superar a su creador. En relación a la segunda cuestión, al entender que la IA es una especie de consultor ésta se responde también negativamente dado que, si bien la IA puede suplantar algún trabajo repetitivo, este déficit se ve compensado por otros muchos puestos de trabajo a los que beneficia, o incluso crea nuevos puestos de trabajo; además, la IA ampliaría nuestro conocimiento del medio, y reduciría la incertidumbre generando modelos más exactos de la realidad.

Ahora bien, puede entenderse también que la posición anterior es limitada en su perspectiva, aplicando un antropomorfismo que busca mantener todo bajo el control humano, aceptando parcialmente lo que no lo es, siempre que quede subyugado a los intereses humanistas.

Efectivamente, es falaz que todo aquello nacido de una cosa sea necesariamente siempre dependiente de su origen en todos los aspectos; y el propio ser humano es un ejemplo de ello. Provenimos de especies mucho más elementales que nosotros, es decir, no solo hemos superado a otros homínidos prehistóricos que nos precedieron, algunos con los que compartimos parentesco, sino también a organismos anteriores más simples aún, incluso unicelulares, como bacterias y protozoos que generaron las primeras combinaciones genéticas que nos hicieron posibles, y que hoy coexisten con nosotros. Entonces, ¿por qué una parte de esa descendencia iba a ser soberana sobre las demás, en tanto que más compleja y evolucionada como suponen los humanistas? La misma situación puede, y debe, aplicarse a la IA: ¿Por qué no una parte de nuestra descendencia puede superar a su progenitor? ¿No

*What AI Can Do, Strengths and Limitations of Artificial Intelligence, Eds. Manuel Cebral-Loureda, Elvira G. Rincón-Flores, Gildardo Sanchez-Ante ISBN 9781032396002, 458 Pages August 1, 2023 by Chapman & Hall

© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

puede ser, más bien, que el ser humano es una parte de algo más amplio, que es la razón, la inteligencia, la mente o el *nous* como decían los antiguos?

El libro que ahora sale a la luz, *What AI can do?*, pretende precisamente dar contexto a las cuestiones anteriores, sin necesariamente posicionarse exactamente en una respuesta única. Por ello, el título es abierto, y pretende reflexionar sobre la IA desde una perspectiva amplia, que pivota sobre tres enfoques: (1) desde un plano más conceptual, qué se dice de la IA, esto es, cuál es su concepción desde la filosofía, la ética, la sociología, y la antropología; (2) cómo la IA se está aplicando interdisciplinarmente en muchos campos de la sociedad, como la educación, el arte, o el derecho; y (3) qué nos pueden decir los ingenieros acerca de qué es realmente posible y qué no en IA, esto es, al margen de las construcciones teóricas, cuáles son los actuales límites y avances de la IA, de manera que podamos continuar con nuestra proyección de posibilidades para un futuro a mediano y largo plazo. La primera sección muestra tanto el potencial transformador de la IA respecto de nuestra concepción de la mente (Cebral-Loureda) como su papel más cuestionable respecto de las plataformas (Sued, Baldi). También ilustra sobre u performatividad respecto a cuestiones de género y cultura (Ricaurte) y nos hace ver que la IA nos obliga a repensar genuinamente la ética (Ritcher), o de que sus efectos son plásticos, es decir, pueden resignificarse artística y políticamente (Bañuelos).

La segunda sección está compuesta de siete capítulos, los cuales muestran las aplicaciones de la IA en diversas áreas como la educación, la medicina, la arquitectura, el derecho y el arte. Los capítulos abordan la IA de manera entusiasta, pero al mismo tiempo con una perspectiva crítica, pues si bien es cierto que la IA ofrece beneficios a la humanidad, todavía existen zonas oscuras que se deberán iluminar. Por ejemplo, es valioso contar con algoritmos que permitan predecir el desempeño académico de los estudiantes para identificar casos de riesgo, pero ¿existen implicaciones al utilizar el reconocimiento facial como variable predictiva? ¿de qué tipo? Por otro lado, hasta qué punto las ciudades inteligentes privilegian ciertos estratos sociales o será posible que promuevan una igualdad social. Así, esta sección invita al lector a enterarse de algunas aplicaciones de la IA bajo una perspectiva práctica y realista.

Por lo que respecta a la tercera sección del libro, compuesta por un total de ocho capítulos, el propósito de los mismos es abordar los escenarios a los que se puede llegar en diferentes áreas del conocimiento según los distintos especialistas. Se trata de un ejercicio más imaginativo donde, en línea con pensamientos experimentales de gran utilidad en ciencia y filosofía, se pueden proyectar y evaluar las consecuencias del desarrollo de la IA, siempre a partir del conocimiento que aporta cada investigador. Algunos de los temas tratados corresponden al desarrollo de nuevos nanomateriales antimicrobianos con el apoyo de la IA, estudios sobre la salud mental, aplicaciones a la construcción, la intersección con las neurociencias, diagnóstico y seguimiento de padecimientos cardiovasculares a través de la retina y aspectos muy interesantes sobre la robustez de la IA contemporánea.

En resumen, qué puede hacer la IA es una pregunta abierta, que probablemente se tenga que actualizar constantemente, ofreciendo no sólo distintas respuestas prácticas sobre sus campos de aplicación, sino nuevas connotaciones positivas y negativas de sus usos, nuevos condicionamientos éticos y epistémicos que acompañan a su avance, así como nuevas áreas del conocimiento y la existencia que se ven afectadas por su emergencia y despliegue. Qué es lo que puede hacer la IA en cada momento, cómo se trazará esa trayectoria para realizarlo es una pregunta relevante de carácter interdisciplinar que se debe formular ya, y cuya respuesta nadie puede llegar a consumar de manera exclusiva: recordando al filósofo Spinoza, nadie sabe qué es lo que puede hacer la IA.✷



© 2024 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Si te cuidas **tú**, nos cuidamos **todos**

Todos podemos hacer algo para mitigar y contener la expansión de las enfermedades. Lo primero siempre es entender qué son, cómo se transmiten y cómo afectan.

En este caso, se trata del coronavirus SARS-COV2. Apareció en China en diciembre pasado y provoca una enfermedad llamada COVID-19, que se ha extendido por el mundo y fue declarada pandemia global por la Organización Mundial de la Salud.

Medidas de prevención



LAVA TUS MANOS CON AGUA Y JABÓN



ACUDE AL MÉDICO SOLO EN UNA URGENCIA



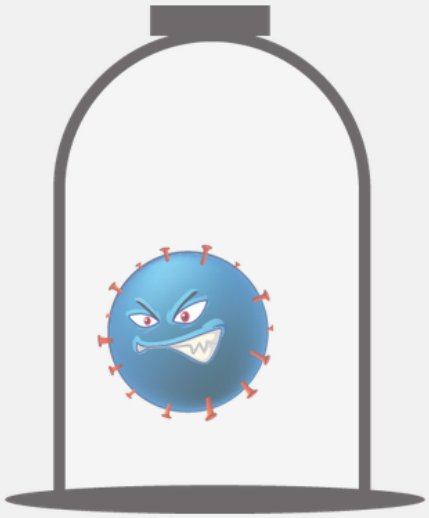
TOSE O ESTORNUDA EN LA PARTE INTERNA DE TU CODO



NO DIFUNDAS NOTICIAS FALSAS

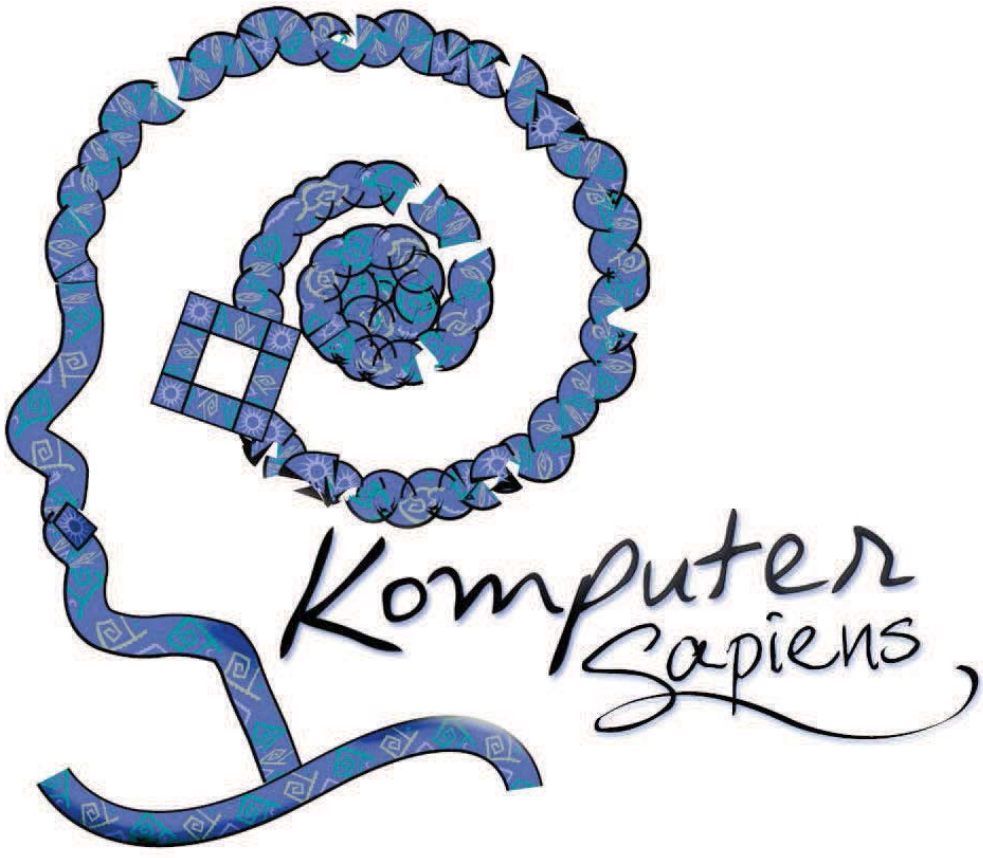
Atendiendo las normas de la Nueva Normalidad y cuidándonos unos a otros podremos salir adelante.

¡SI AISLAMOS AL VIRUS, LO VENCEREMOS!



Información tomada de: https://coronavirus.gob.mx

Indizada en el IRMDCT de CONACYT y en Latindex



¡Publique en Komputer Sapiens!

CONACYT
ÍNDICE DE REVISTAS MEXICANAS DE DIVULGACIÓN CIENTÍFICA Y TECNOLÓGICA (IRMDCT)

Komputer Sapiens solicita artículos de divulgación en todos los temas de Inteligencia Artificial, dirigidos a un amplio público conformado por estudiantes, académicos, empresarios, tomadores de decisiones y consultores. Komputer Sapiens es patrocinada por la **SMIA, la Sociedad Mexicana de Inteligencia Artificial**

SMIA
www.smia.org.mx

Instrucciones para autores e información general: http://www.komputersapiens.org
Síguenos en las redes sociales: www.facebook.com/Komputer.Sapiens, twitter.com/KomputerSapiens