



TEC TUXTLA

ISSN: 2992-7889

*Revista de Divulgación Científica
del Instituto Tecnológico de
Tuxtla Gutiérrez*

No. 2 Publicación Semestral
Semestre **Julio - Diciembre**

20

23





CINTILLO LEGAL

TEC TUXTLA, número 1, enero – junio 2023, es una publicación semestral editada por el Tecnológico Nacional de México, Avenida Universidad 1200, Alcaldía Benito Juárez, C.P. 03330, teléfono 5536002511 Ext. 65092, correo d_vinculacion05@tecnm.mx, a través del Instituto Tecnológico de Tuxtla Gutiérrez, Carretera Panamericana km. 1080, C.P. 29050. Tuxtla Gutiérrez, Chiapas, México. Contacto: 01 961 615 0461, plan_tgutierrez@tecnm.mx, www.tuxtla.tecnm.mx. Editor Responsable: Luis Alberto Pérez Lozano. Reserva de Derechos al Uso Exclusivo: 04-2023-041116373200-102, ISSN: 2992-7889, ambos otorgados por el Instituto Nacional de Derechos de Autor. Responsable de la última actualización de este Número, Departamento de Comunicación y Difusión, Ana Erika Pérez Galindo, Carretera Panamericana km. 1080 C.P 29050. Tuxtla Gutiérrez, Chiapas, México. Fecha de la última modificación: 23 de mayo de 2023.

Queda prohibida la reproducción total o parcial en cualquier medio, del contenido de la presente revista electrónica, sin contar con la autorización del Instituto Tecnológico de Tuxtla Gutiérrez.

Presidente del Consejo Editorial

Luis Alberto Pérez Lozano

Subdirección de Planeación y Vinculación

Correo: plan_tgutierrez@tecnm.mx

Teléfono: 961 615 0461 extensiones: 400, 401

URL de la Revista: <http://revista.tuxtla.tecnm.mx/>



Director del Instituto Tecnológico de Tuxtla Gutiérrez

José Manuel Rosado Pérez

CONSEJO EDITORIAL

Presidente del Consejo Editorial

Luis Alberto Pérez Lozano
Subdirección de Planeación y Vinculación

Secretaria Técnica del Consejo Editorial

Ana Erika Pérez Galindo
Departamento de Comunicación y Difusión

MIEMBROS

Juan Carlos Niños Torres

División de Estudios Profesionales

Amín Rodríguez Meneses

*Departamento de División de Estudios
de Posgrado e Investigación*

José Rigoberto Ruiz Gamboa

Departamento de Recursos Materiales

René Arjón Castro

Centro de Información

Francisco Rangel Genovés Genovés

Oficina Editorial

Juan Carlos Morales Noriega

Oficina de Maquetación

Ethel Rosalí Vázquez del Porte

Oficina Difusión Audiovisual

COMITÉ EDITORIAL

Miguel Abud Archila

Rocío Meza Gordillo

Victor Manuel Ruiz Valdiviezo

Madaín Pérez Patricio Carlos Ríos Rojas

Héctor Ricardo Hernández de León

Carlos Arias Castro

Pedro Tomas Ortiz y Ojeda

Idelberto de los Santos Ruiz

Edna Moráles Coutiño

Miguel Cid del Prado Martínez



Tabla de contenido

Importancia de la bioquímica y metagenómica en los estudios de la microbiota gastrointestinal: una revisión	4
Algoritmo de procesamiento de lenguaje natural para la prevención temprana de violencia de género.....	19
Sistema IoT para la detección de armas utilizando el área de detección como umbral de seguridad.....	30
Detección de armas mediante visión artificial utilizando técnicas de aumentación de datos.....	47



Importancia de la bioquímica y metagenómica en los estudios de la microbiota gastrointestinal: una revisión

García-Gálvez, Leslie^{1*}, Del Carpio Vidal, Rodolfo¹, Ruíz Valdiviezo, Víctor Manuel¹

¹Tecnológico Nacional de México campus Tuxtla Gutiérrez, Chiapas.

*Autor para correspondencia: Lesliegarcialvarez2@gmail.com

Contactos:

Leslie García Gálvez. Tecnológico Nacional de México campus Tuxtla Gutiérrez. Correo: Lesliegarcialvarez2@gmail.com Tel: 9612843137

Rodolfo del Carpio Vidal. Tecnológico Nacional de México campus Tuxtla Gutiérrez. Correo: rodolfo.dcvidal@gmail.com Tel: 9611810794

Víctor Manuel Ruíz-Valdiviezo. Tecnológico Nacional de México campus Tuxtla Gutiérrez. Correo: bioqvic@hotmail.com Tel:9612361772

Área de conocimiento:

Este trabajo se encuentra dentro del área de bioquímica y biología molecular.



Semblanzas:



Leslie García Gálvez: Ingeniera Bioquímica egresada del Tecnológico Nacional de México campus Tuxtla Gutiérrez. Actualmente, cursa sus estudios de Maestría en Ciencias en Ingeniería Bioquímica-PNPC del ITTG. Durante sus estudios de ingeniería realizó dos estancias de verano científico, la primera en la Universidad Nacional Autónoma de México, CDMX estudiando a “*Drosophila Melanogaster silvestre* y transgénicas expuestas a plaguicidas cetoenoles” y la segunda estancia de investigación en la Universidad Autónoma de Baja California evaluando el “Efecto biológico de *Stevia rebaudiana bertooni* biofortificada con nanopartículas de ZnO en ratones con Diabetes *mellitus* tipo 2”. Para concluir sus estudios de licenciatura, Leslie desarrolló la tesis “Evaluación de la proliferación del hepatocarcinoma AS30D en microbiota gastrointestinal de ratas Wistar” en el Instituto Nacional de Cardiología Ignacio Chávez.



Rodolfo Del Carpio Vidal: Estudiante de Licenciatura en Ingeniería Bioquímica en el Tecnológico Nacional de México campus Tuxtla Gutiérrez (ITTG). Actualmente, para terminar sus estudios de licenciatura, está realizando la Tesis en el Instituto Nacional de Cardiología Ignacio Chávez. Durante sus estudios de ingeniería realizó una estancia de verano científico en la Universidad Nacional Autónoma de México, CDMX donde realizó el proyecto "Subclonación del gen de la orotato fosforribosiltransferasa de *Pseudomonas cichorii*", además de exponer dicho proyecto en el Congreso Internacional del XXVII Verano de la Investigación Científica y Tecnológica del Pacífico.



Víctor Manuel Ruíz Valdiviezo: Ingeniero Bioquímico y Maestro en Ciencias en Ingeniería Bioquímica egresado del Instituto Tecnológico de Tuxtla Gutiérrez. Después, cursó sus estudios del Doctorado en Ciencias en Biotecnología en el Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional. Actualmente es Profesor Investigador del Instituto Tecnológico de Tuxtla Gutiérrez. Es miembro del Sistema Nacional de Investigadores nivel 2, del Sistema Estatal de Investigadores (Miembro Honorífico, SEI, Chiapas) y profesor con Perfil deseable PRODED. Recibió el reconocimiento al Mérito Estatal de Investigación 2014 (categoría Juvenil) por parte del gobierno del estado de Chiapas. Actualmente imparte clases en la licenciatura de Ingeniería Bioquímica, la Maestría en Ciencias en Ingeniería Bioquímica-PNPC y el Doctorado en Ciencias de los Alimentos y Biotecnología-PNPC. En materia de productividad científica ha publicado 106 artículos en revistas internacionales, y cuenta con 1 título de patente, así como también ha participado en diversos eventos académicos a nivel nacional e internacional, y estancias internacionales en Estados Unidos, Bélgica y Alemania.

Resumen:

La microbiota gastrointestinal contiene aproximadamente de 10^{12} a 10^{14} microorganismos, los cuales desempeñan un papel central en la biología del huésped, una de las actividades importantes es el suministro de nutrientes. Los microorganismos del tracto gastrointestinal son de suma importancia por sus capacidades metabólicas, ya que estas pueden afectar el estado nutricional del huésped. En el presente artículo se trata de dar énfasis a los esfuerzos por aclarar la bioquímica para el metabolismo microbiano gastrointestinal de los componentes de la dieta y el uso de técnicas de biología molecular como la metagenómica.

Palabras clave: Microbiota gastrointestinal, Metagenómica, Biología molecular

Introducción

El cuerpo humano esta colonizado por una gran diversidad de bacterias, arqueas, virus y eucariotas unicelulares, estos microorganismos habitan principalmente la superficie epitelial del cuerpo humano. Una gran cantidad habita el tracto gastrointestinal, aproximadamente más de mil especies microbianas que forman una compleja comunidad ecológica llamada microbiota gastrointestinal (MGI). La MGI ha sido recientemente clasificada como un “órgano vital” debido a su conexión o eje multidireccional y comunicacional con otros órganos mediante vías neurales, endocrinas, humorales, inmunológicas y metabólicas. (Afzaal et al., 2022).

Actualmente, su composición y función se consideran un área de investigación fascinante de gran relevancia en la salud contemporánea. Técnicas como los estudios metagenómicos y bioquímicos han permitido comprender mejor la complejidad y la funcionalidad de la MGI. Por un lado, las técnicas metagenómicas permiten un análisis del ADN microbiano presente en muestras fecales, o en cultivos de MGI, proporcionando información sobre su composición taxonómica, así como su diversidad y abundancia (Jin et al., 2022; Zhang et al., 2021).

Por otro lado, los estudios bioquímicos ayudan a identificar y caracterizar metabolitos, enzimas y vías metabólicas, lo que permite profundizar en los mecanismos moleculares entre la MGI y el hospedero (Catalkaya et al., 2020; Tanes et al., 2021).



En conjunto, estas herramientas han revelado una sorprendente diversidad microbiana entre individuos, así como variaciones significativas asociadas con factores como la edad, la dieta, el estilo de vida, la genética y el estado de salud, además de respaldar que la MGI se ve implicada en varios procesos metabólicos (Afzaal et al., 2022). Esto nos permite comprender más a fondo a la MGI, facilitando el camino para el desarrollo de enfoques terapéuticos más precisos y personalizados que aprovechen el potencial de esta comunidad microbiana.

El presente artículo está enfocado en conocer la importancia de los estudios metagenómicos y bioquímicos de la MGI, así como su aportación para ampliar el conocimiento de su taxonomía y funcionalidad.

¿Metagenómica? ¿Cómo nos ayuda a estudiar a la MGI?

La metagenómica se basa en el uso de técnicas de biología molecular para analizar la diversidad de genomas microbianos, llamados también metagenomas, mediante marcadores moleculares para clasificar bacterias y arqueas en grupos taxonómicos a nivel de género. En los primeros estudios de diversidad microbiana de muestras ambientales se utilizaban métodos dependientes de cultivo (Cortés-López et al., 2020).

Mediante el avance de las técnicas de biología molecular, se ha logrado analizar la diversidad microbiana a través del uso de métodos independientes de cultivo (Figura 1), uno de estos métodos más usados es la amplificación por PCR de fragmentos del gen 16S rRNA y en algunos casos seguida de electroforesis en gel de gradiente desnaturizante. El gen 16S rRNA, codifica para el ARN ribosómico que conforma la subunidad pequeña de los ribosomas. Este gen comprende regiones conservadas y variables en bacterias y arqueas, actualmente, se ha utilizado como marcador molecular, ya que permite clasificar a las bacterias y arqueas en grupos taxonómicos de acuerdo con las familias o géneros (Cortés-López et al., 2020).

Otra técnica es la secuenciación masiva del metagenoma por “shotgun” tiene la característica de secuenciar todo el ADN presente en la muestra por lo que se pueden clasificar a los microorganismos taxonómicamente hasta el nivel de especie. Además, con las secuencias obtenidas por este tipo de secuenciación se pueden llegar a descubrir genes con funciones



nunca antes descritas e incluso se pueden seleccionar las secuencias que pertenecen al gen 16S rRNA para realizar anotaciones taxonómicas (Cortés-López et al., 2020).

La amplificación de regiones seleccionadas del gen 16S rRNA, en específico de las regiones V1, V2, V3 y V6 ha sido hasta ahora una de las más usadas para el estudio del ecosistema gastrointestinal humano, en algunos de los primeros estudios realizados donde se utilizó esta técnica, se logró conocer una composición más específica de la MGI, teniendo 6-10 filos bacterianos por individuo, siendo estos: *Acidobacterias*, *Actinobacterias*, *Bacteroidetes*, *Firmicutes*, *Fusobacterias*, *Lentisphaerae*, *Proteobacteria*, *Verrucomicrobia* y *Deniococcus-Thermus*. De los cuales, *Firmicutes* y *Bacteroidetes* representan hasta un 90% de la MGI con una abundancia relativa de aproximadamente 65 y 25% respectivamente (Marchesi, 2010). Aunado a lo anterior, otros estudios metagenómicos demostraron que un 65% de las bacterias identificadas en la MGI eran previamente desconocidas y un 80% eran incultivables en laboratorio (Peterson et al., 2008).

Estudios actuales han permitido conocer mejor la composición de la MGI dando a conocer que la mayoría de las bacterias (99%) en el tracto gastrointestinal son anaerobias siendo los filos dominantes *Firmicutes*, *Bacteroidetes*, *Actinobacteria* y *Proteobacteria* y los géneros mayormente reportados son *Bacteroides*, *Clostridium*, *Peptococcus*, *Bifidobacterium*, *Eubacterium*, *Ruminococcus*, *Faecalibacterium* y *Peptostreptococcus* (Gomaa, 2020).




Figura 1. Metodología general de un estudio metagenómico



Estudios bioquímicos y su importancia

Se ha demostrado que los microorganismos que conforman la MGI desempeñan funciones integrales en el metabolismo de nutrientes y la degradación de compuestos no digeribles. Actualmente hay una deficiencia en la comprensión en cuanto al estudio de las actividades metabólicas y su relación con los microorganismos y sus genes (Sharon et al., 2014). En este artículo se pretende destacar los avances en cuanto al tipo de conexión que tienen los microorganismos del intestino con el metabolismo, transporte de nutrientes y enzimas implicadas en el metabolismo (Figura 2).

Metabolismo de polisacáridos:

Los polisacáridos complejos no son digeribles por las enzimas del tracto gastrointestinal del huésped, pero son metabolizadas por parte de la MGI (Porter & Martens, 2017). Los productos finales de la fermentación de polisacáridos en el intestino son los ácidos orgánicos de cadena corta (AOCC). Los AOCC como el propionato, butirato y acetato desempeñan un papel importante en la nutrición y homeostasis al ser una fuente de energía importante, ya que puede representar aproximadamente el 10% de los requerimientos calóricos diarios (den besten 2013), los AOCC no solo funcionan como fuente de energía, sino que interactúan con proteínas y receptores (GPR) que son importantes en la regulación del metabolismo de los lípidos y glucosa.

Los azúcares simples son de suma importancia para poder obtener energía de una manera más rápida, sin embargo, para poder tener acceso a estos, es necesario que la MGI hidrolice una amplia gama de enlaces glicosídicos (Kaoutari 2013), existe un grupo de enzimas que ayuda para que puedan hidrolizarse, este grupo de enzimas que cataliza estas transformaciones son las enzimas que actúan sobre carbohidratos (CAZymes). La expresión de estas CAZymes puede verse influenciada por la disponibilidad de sustratos específicos y la presencia de otros algunos microorganismos de la MGI (Chittim 2018), comprender estas enzimas, sus especificidades, su regulación y su distribución en el intestino ayuda a evaluar qué polisacáridos son procesados por ciertas comunidades de la MGI y de esta manera poder predecir la respuesta a algunas dietas, intervenciones o prebióticos destinados a estimular actividades de los microbios intestinales beneficiosos.



Metabolismo de aminoácidos:

Los seres humanos obtienen los aminoácidos a partir de las proteínas de la dieta y de la síntesis de *novo* por la MGI (neis 2015), las enzimas de la MGI hidrolizan las proteínas ingeridas para liberar los componentes básicos y las capacidades proteolíticas del tracto gastrointestinal.

Los análisis genómicos han demostrado que la MGI codifica proteasas, peptidasas y péptidos de aminoácidos, los cuales pueden afectar el metabolismo de los aminoácidos dentro del huésped (Portune 2016). Los aminoácidos están sujetos a transformaciones por parte de la MGI. Muchas de estas vías son exclusivamente microbianas, por ejemplo, la fermentación de Stickland que involucra dos aminoácidos: el primero que se oxida y desamina y el segundo que actúa como aceptor de los electrones del primero, reduciéndose y obteniéndose cetoácidos que son empleados para la síntesis de ATP por fosforilación a nivel de sustrato, esta ruta es importante para la producción de energía en el intestino humano desempeñando este proceso metabólico un papel especialmente papel importante en la colonización del intestino humano por *Clostridium difficile* (jenior 2017).

La producción de indol del triptófano es realizada por diversas especies dentro de la MGI, el metabolito sulfato de indoxilo es una toxina urémica (Davila 2013), de este modo, la conversión microbiana gastrointestinal de tirosina en *p*-cresol se ha relacionado con el autismo y la producción excesiva de este metabolito puede interferir con el metabolismo del huésped de fármacos como el paracetamol (Clayton 2009).

Metabolismo de lípidos:

Los lípidos son moléculas presentes en la dieta que interactúan con la MGI, los lípidos presentes en el colon provienen de la bilis liberada en el tracto gastrointestinal (Begley et al., 2006). Las sales biliares se sintetizan en el hígado con núcleos de esteroides que están conjugados con taurina o glicina. Las hidrolasas (BSH) son el paso clave en la regulación de las vías de circulación y excreción de los ácidos biliares, estas enzimas BSH están presentes en muchas bacterias intestinales, como: *Bacteroides fragilis* y *Clostridium perfringens*, *Bifidobacterium longum* y *Lactobacillus plantarum*, además de las BSH, también los aislados intestinales pueden generar ácidos biliares secundarios por medio de una modificación en la estructura de esteroides.

Metabolismo de nutrientes esenciales:

La microbiota intestinal puede afectar positivamente la disponibilidad de nutrientes críticos para el huésped, esto puede ocurrir mediante la modulación microbiana de las vías de absorción de nutrientes del huésped, liberación de nutrientes de la dieta y síntesis de *novo* de nutrientes como las vitaminas esenciales (LeBlanc et al., 2013). Es posible que la ingesta diaria recomendada de vitaminas no siempre se pueda alcanzar sólo con la dieta, por ejemplo, en el caso de la desnutrición. La síntesis bacteriana de ácido fólico, biotina, riboflavina y vitamina K, pueden ayudar a las necesidades nutricionales insatisfechas (Chittim et al., 2018).

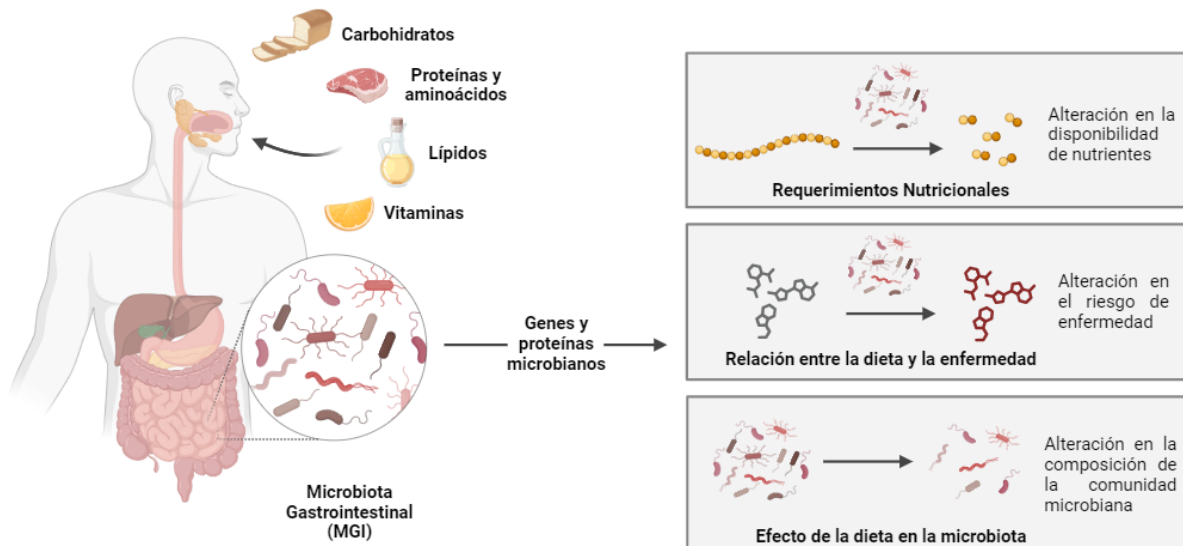


Figura 2. El rol central de la bioquímica en el entendimiento de las interacciones MGI-nutrientes.

Factores que afectan la composición y funcionalidad de la MGI

Gracias a varios estudios metagenómicos y bioquímicos, se ha podido determinar que existen factores como la edad, la dieta, el estilo de vida, la genética y el estado de salud que afectan la composición y funcionalidad de la MGI (figura 3), a estas alteraciones, se le conoce como disbiosis (Ling et al., 2022; Sanders et al., 2019).




Figura 3. Factores que generan disbiosis en la MGI.

Edad

La colonización de la microbiota aparece inmediatamente después del nacimiento, las primeras cepas bacterianas en aparecer en los intestinos son cepas aerobias del filo Proteobacteria, las cuales disminuyen la concentración de oxígeno, permitiendo posteriormente la colonización de cepas anaerobias como Firmicutes, Actinobacteria y Bacteroidetes; esta composición va cambiando a lo largo del desarrollo del hospedero. En la niñez (2-5 años) la composición de la MGI se vuelve más estable con mayor número de Firmicutes y Bacteroidetes, incluyendo los que tienen la capacidad productora de butirato. Después, en la etapa preadolescente (7-12 años), la MGI se enriquece en funciones sintéticas de folato y vitamina B-12. Luego, en la adolescencia (11-18 años) la abundancia de los géneros *Clostridium* y *Bifidobacterium* son mayores. Posteriormente en la etapa adulta (>18 años) una MGI sana está predominada por Firmicutes y Bacteroidetes, incluyendo en menor proporción a Verrucomicrobia, Actinobacteria y Proteobacteria. Finalmente, en la vejez (>65 años) la MGI ha sido caracterizada por presentar un declive en la diversidad microbiana, disminuyendo los Bacteroidetes, Firmicutes y especies productoras de AOCC e incrementando la abundancia de patógenos oportunistas pertenecientes a la familia Enterobacteriaceae (Gomaa, 2020).



Dieta

La dieta del hospedero puede modular la composición de la MGI incrementando o disminuyendo las especies en el ambiente intestinal. Por ejemplo, las dietas vegetarianas han demostrado que están relacionadas con buena salud intestinal teniendo la presencia de Firmicutes y Bacteroidetes como las especies dominantes (Ray, 2018); mientras que dietas altas en proteínas y lípidos, han sido reportadas por aumentar la abundancia de especies como Bacteroides, Bilophila y Alistipes reprimiendo a los Firmicutes (Forouhi et al., 2018). Asimismo, cierto tipo de dietas, en especial la mencionada previamente, está relacionada con el desarrollo de enfermedades como obesidad o diabetes tipo 2, de las cuales se hablará más adelante.

Factores genéticos

El genotipo del hospedero también se ha visto relacionado con diferencias en la diversidad y estructuras comunitarias específicas de la MGI, por ejemplo, así como algunos genes afectan la funcionalidad del sistema inmune aumentando la susceptibilidad a enfermedades, ciertos alelos están asociados a cierta composición microbiana en el tracto gastrointestinal, individuos con la variante rs651821 del gen *APOA5* son más probables a tener miembros de los géneros *Lactobacillus*, *Sutterella* y *Methanobrevibacter* que están correlacionados a un mayor riesgo de padecer desordenes metabólicos (Bander et al., 2020)

Estilo de vida

Algunos hábitos del hospedero afectan también la composición de la microbiota gastrointestinal, por ejemplo, el nivel de actividad física, se asocian positivamente con la diversidad alfa bacteriana en humanos sanos, además, algunos estudios informaron una asociación positiva entre la actividad física/la aptitud cardiorrespiratoria y la concentración fecal de AOCC (Ortiz-Alvarez et al., 2020). Por otro lado, se ha determinado que el humo del tabaco afecta la composición de la MGI, *Prevotella* spp. aparece significativamente aumentado en fumadores y exfumadores, pero no en usuarios de cigarrillos electrónicos, mientras que Proteobacteria mostró un aumento progresivo de Desulfovibrio con el número de paquetes por año de cigarrillo y un aumento de Alfarproteobacterias en fumadores actuales versus nunca fumadores (Antinozzi et al., 2022).



Estado de salud

Análisis conjuntos de datos multiómicos, incluidos datos de metagenómica y metabolómica han determinado que muchas enfermedades están relacionadas con la MGI, estas enfermedades generan un estado de disbiosis que va desencadenando alteraciones que pueden influir en la progresión y la manifestación de las condiciones patológicas. Lo anterior se reportó en desordenes metabólicos como obesidad, diabetes tipo 2, enfermedad hepática no alcohólica, enfermedades cardio metabólicas y desnutrición (Fan & Pedersen, 2021).

Conclusión

En base a lo mencionado anteriormente podemos concluir que estudiar la microbiota gastrointestinal es de suma importancia por la relación que tiene con el apareamiento y proliferación de algunas enfermedades, es por eso que los estudios bioquímicos y metagenómicos son importantes para poder tener un entendimiento amplio y claro sobre la relación entre la diversidad y abundancia de microorganismos con las funciones que tienen en el metabolismo del huésped, aunque aún queda mucho por investigar, con las investigaciones que hay hasta el momento deja una brecha en este campo para los investigadores en el área de bioquímica, enzimología y biología molecular.



Referencias

- Afzaal, M., Saeed, F., Shah, Y. A., Hussain, M., Rabail, R., Socol, C. T., Hassoun, A., Pateiro, M., Lorenzo, J. M., Rusu, A. V., & Aadil, R. M. (2022). Human gut microbiota in health and disease: Unveiling the relationship. *Frontiers in Microbiology*, 13. <https://doi.org/10.3389/fmicb.2022.999001>
- Al Bander, Z., Nitert, M. D., Mousa, A., & Naderpoor, N. (2020). The Gut Microbiota and Inflammation: An Overview. *International Journal of Environmental Research and Public Health*, 17(20), 7618. <https://doi.org/10.3390/ijerph17207618>
- Antinozzi, M., Giffi, M., Sini, N., Gallè, F., Valeriani, F., De Vito, C., Liguori, G., Romano Spica, V., & Cattaruzza, M. S. (2022). Cigarette Smoking and Human Gut Microbiota in Healthy Adults: A Systematic Review. *Biomedicines*, 10(2), 510. <https://doi.org/10.3390/biomedicines10020510>
- Begley, M., Hill, C., & Gahan, C. G. M. (2006). Bile Salt Hydrolase Activity in Probiotics. *Applied and Environmental Microbiology*, 72(3), 1729–1738. <https://doi.org/10.1128/AEM.72.3.1729-1738.2006>
- Catalkaya, G., Venema, K., Lucini, L., Rocchetti, G., Delmas, D., Daglia, M., De Filippis, A., Xiao, H., Quiles, J. L., Xiao, J., & Capanoglu, E. (2020). Interaction of dietary polyphenols and gut microbiota: Microbial metabolism of polyphenols, influence on the gut microbiota, and implications on host health. *Food Frontiers*, 1(2), 109–133. <https://doi.org/10.1002/fft2.25>
- Chittim, C. L., Irwin, S. M., & Balskus, E. P. (2018). Deciphering Human Gut Microbiota–Nutrient Interactions: A Role for Biochemistry. *Biochemistry*, 57(18), 2567–2577. <https://doi.org/10.1021/acs.biochem.7b01277>
- Cortés-López, N. G., Ordóñez-Baquera, P. L., & Domínguez-Viveros, J. (2020). Herramientas moleculares utilizadas para el análisis metagenómico. Revisión. *Revista Mexicana de Ciencias Pecuarias*, 11(4), 1150–1173. <https://doi.org/10.22319/rmcp.v11i4.5202>
- Fan, Y., & Pedersen, O. (2021). Gut microbiota in human metabolic health and disease. *Nature Reviews Microbiology*, 19(1), 55–71. <https://doi.org/10.1038/s41579-020-0433-9>



- Forouhi, N. G., Krauss, R. M., Taubes, G., & Willett, W. (2018). Dietary fat and cardiometabolic health: evidence, controversies, and consensus for guidance. *BMJ*, k2139. <https://doi.org/10.1136/bmj.k2139>
- Gomaa, E. Z. (2020). Human gut microbiota/microbiome in health and diseases: a review. *Antonie van Leeuwenhoek*, 113(12), 2019–2040. <https://doi.org/10.1007/s10482-020-01474-7>
- Jin, H., You, L., Zhao, F., Li, S., Ma, T., Kwok, L.-Y., Xu, H., & Sun, Z. (2022). Hybrid, ultra-deep metagenomic sequencing enables genomic and functional characterization of low-abundance species in the human gut microbiome. *Gut Microbes*, 14(1). <https://doi.org/10.1080/19490976.2021.2021790>
- LeBlanc, J. G., Milani, C., de Giori, G. S., Sesma, F., van Sinderen, D., & Ventura, M. (2013). Bacteria as vitamin suppliers to their host: a gut microbiota perspective. *Current Opinion in Biotechnology*, 24(2), 160–168. <https://doi.org/10.1016/j.copbio.2012.08.005>
- Ling, Z., Liu, X., Cheng, Y., Yan, X., & Wu, S. (2022). Gut microbiota and aging. *Critical Reviews in Food Science and Nutrition*, 62(13), 3509–3534. <https://doi.org/10.1080/10408398.2020.1867054>
- Marchesi, J. R. (2010). *Prokaryotic and Eukaryotic Diversity of the Human Gut* (pp. 43–62). [https://doi.org/10.1016/S0065-2164\(10\)72002-5](https://doi.org/10.1016/S0065-2164(10)72002-5)
- Peterson, D. A., Frank, D. N., Pace, N. R., & Gordon, J. I. (2008). Metagenomic Approaches for Defining the Pathogenesis of Inflammatory Bowel Diseases. *Cell Host & Microbe*, 3(6), 417–427. <https://doi.org/10.1016/j.chom.2008.05.001>
- Porter, N. T., & Martens, E. C. (2017). The Critical Roles of Polysaccharides in Gut Microbial Ecology and Physiology. *Annual Review of Microbiology*, 71(1), 349–369. <https://doi.org/10.1146/annurev-micro-102215-095316>
- Ray, K. (2018). Filling up on fibre for a healthy gut. *Nature Reviews Gastroenterology & Hepatology*, 15(2), 67–67. <https://doi.org/10.1038/nrgastro.2018.2>
- Sanders, M. E., Merenstein, D. J., Reid, G., Gibson, G. R., & Rastall, R. A. (2019). Probiotics and prebiotics in intestinal health and disease: from biology to the clinic. *Nature Reviews Gastroenterology & Hepatology*, 16(10), 605–616. <https://doi.org/10.1038/s41575-019-0173-3>



-
- Sharon, G., Garg, N., Debelius, J., Knight, R., Dorrestein, P. C., & Mazmanian, S. K. (2014). Specialized Metabolites from the Microbiome in Health and Disease. *Cell Metabolism*, 20(5), 719–730. <https://doi.org/10.1016/j.cmet.2014.10.016>
- Tanes, C., Bittinger, K., Gao, Y., Friedman, E. S., Nessel, L., Paladhi, U. R., Chau, L., Panfen, E., Fischbach, M. A., Braun, J., Xavier, R. J., Clish, C. B., Li, H., Bushman, F. D., Lewis, J. D., & Wu, G. D. (2021). Role of dietary fiber in the recovery of the human gut microbiome and its metabolome. *Cell Host & Microbe*, 29(3), 394-407.e5. <https://doi.org/10.1016/j.chom.2020.12.012>
- Zhang, Q., Yu, K., Li, S., Zhang, X., Zhao, Q., Zhao, X., Liu, Z., Cheng, H., Liu, Z.-X., & Li, X. (2021). gutMEGA: a database of the human gut MEtaGenome Atlas. *Briefings in Bioinformatics*, 22(3). <https://doi.org/10.1093/bib/bbaa082>



Algoritmo de procesamiento de lenguaje natural para la prevención temprana de violencia de género

José-Armando Fragoso-Mandujano, Sheyla K. Flores-Guirao, Esvan-Jesús Pérez-Pérez
Tecnológico Nacional de México campus Tuxtla Gutiérrez, Carretera Panamericana S/N,
Tuxtla Gutiérrez, Chiapas, México, C.P. 29050.

jose.fm@tuxtla.tecnm.mx, sheyla.fg@tuxtla.tecnm.mx, esvandejesus@gmail.com

Resumen: Este artículo aborda la grave y compleja problemática de la violencia de género en México, destacando que una de cada tres mujeres en el país ha sido víctima de este tipo de violencia y enfrenta un incremento en los casos de feminicidio. La violencia se manifiesta de múltiples formas y se ve agravada por una cultura patriarcal y machista, y a pesar de los avances legislativos, la impunidad sigue siendo un problema grave. El texto propone un enfoque de inteligencia artificial, específicamente de procesamiento de lenguaje natural, para detectar y prevenir la violencia de género en textos. Este proyecto busca no solo abordar una necesidad social urgente, sino también fomentar el desarrollo y la igualdad de género en México, ofreciendo un paso hacia una sociedad más segura y equitativa para las mujeres.


Palabras clave: Artículo, Divulgación, Ciencia, Tecnología, Innovación.



José-Armando Fragoso-Mandujano, Doctor en ciencias de la ingeniería por el instituto tecnológico de Tuxtla Gutiérrez, especializado en procesamiento de imágenes, inteligencia artificial y sus aplicaciones.:
jose.fm@tuxtla.tecnm.mx



Sheyla K. Flores-Guirao, egresada del Tecnológico Nacional de México campus Tuxtla Gutiérrez de la carrera de gestión empresarial, con gran gusto por el aprendizaje constante y compartir conocimientos. Correo electrónico: sheyla.fg@tuxtla.tecnm.mx



Esvan-Jesús Pérez-Pérez, Doctor en ciencias de la ingeniería en el TecNM campus Tuxtla Gutiérrez en 2023, con intereses en el área de inteligencia artificial y diagnóstico de fallas en sistemas dinámicos basado en datos, sistemas neuro difusos y observadores. Correo electrónico: esvandejesus@gmail.com

Introducción

En México, la violencia de género emerge como una problemática social severa y compleja, transversal a todas las capas de la sociedad. Este fenómeno, que afecta a mujeres de todas las edades, etnias y estratos socioeconómicos, se ha convertido en un tema de urgente atención y acción. El Instituto Nacional de Estadística y Geografía (INEGI) revela datos alarmantes: una de cada tres mujeres en el país ha sido víctima de violencia de género en algún momento de su vida (Mata-Santel, J y col, 2023). La escalada de feminicidios, homicidios de mujeres por razones de género, subraya aún más la gravedad de la situación.

La violencia de género no se limita a un único tipo; abarca desde la violencia física y sexual hasta formas más sutiles, pero igualmente destructivas como la violencia económica y psicológica. Este espectro amplio de abusos refleja la complejidad del problema y la necesidad de abordajes multidimensionales para su resolución. Un obstáculo significativo en la lucha contra esta problemática es la impunidad prevaleciente. A pesar de los avances en legislación y políticas públicas, la realidad es desalentadora: según el Secretariado Ejecutivo del Sistema Nacional de Seguridad Pública (SESNSP), en 2020, solo un porcentaje mínimo de los casos denunciados de violencia sexual condujo a sentencias condenatorias (Velázquez, 2022). Este panorama de impunidad refuerza la necesidad de estrategias más efectivas y comprometidas.

Adicionalmente, la cultura patriarcal y los estereotipos de género en México perpetúan y legitiman la violencia hacia las mujeres. El machismo, con su nociva premisa de dominio masculino sobre las mujeres, sigue siendo un factor determinante en la perpetuación de la violencia de género. Este contexto no solo perpetúa la desigualdad de género, sino que también restringe las oportunidades de desarrollo pleno para las mujeres, afectando su participación en diferentes esferas de la sociedad.

La revolución tecnológica digital juega un papel trascendental en este ámbito social, teniendo un acercamiento fuerte para ayudar a prevenir y combatir la violencia de género. Entre las herramientas desarrolladas se encuentran aplicaciones móviles, plataformas en línea y sistemas de alerta temprana; como Circle of 6, Chayn, Soli, Me too (Sánchez, 2019). Algunas de herramientas son diseñadas para beneficios en temas de seguridad, emitiendo alertas a las autoridades y a las organizaciones de ayuda cuando se presenta una situación de riesgo, otras se centran en brindar soporte emocional y psicológico para mujeres víctimas de sucesos de violencia, estas herramientas incluyen amplia información



mostrándose como una red de apoyo para prevenir la violencia o brindar seguridad y protección según se presente el caso.

Además, también se han desarrollado plataformas y redes sociales para conectar a mujeres víctimas de violencia con otras personas que han experimentado situaciones similares, lo que ofrece una comunidad de apoyo y solidaridad (Monge, 2019). Pese a las diversas aplicaciones que se ofrecen en el mercado, actualmente no existe una plataforma web que permita analizar información y realizar una detección temprana de violencia en conversaciones escritas. El uso de inteligencia artificial actualmente despunta con grandes utilidades, tal como se analizó en la literatura científica.

En este artículo, exploraremos cómo un proyecto llamado “Violencia cero” una aplicación web basada en inteligencia artificial que ofrece una herramienta para identificar textos que incluyan violencia. Este proyecto busca no solo atender una necesidad social crítica sino también contribuir a la construcción de una sociedad más justa y equitativa para las mujeres en México. El proyecto de “Violencia Cero” atiende un problema complejo y arraigado que requiere de un enfoque multifacético y la cooperación de toda la sociedad, además del aprovechamiento del avance tecnológico, como lo es, haciendo uso de inteligencia artificial.

Diseño y desarrollo de la aplicación web

La aplicación permite a los usuarios analizar mensajes e identificar señales de violencia, alertándolos y concientizándolos sobre conductas de abuso que pueden desencadenar situaciones de violencia psicológica hasta física.

Brinda las siguientes funcionalidades:

- Lectura y detección de mensajes en tiempo real.
- Indicadores de violencia.
- Análisis predictivo de situaciones de acoso y violencia.
- Protocolo y recursos para la intervención en casos activos de violencia.
- Enlace para ayuda psicológica con profesionales especializados.

En la Figura 1 se muestra el diagrama de flujo que representa las etapas de funcionamiento de una plataforma web que utiliza procesamiento de lenguaje natural (PLN) para evaluar textos en busca de contenido de violencia de género. El flujo comienza con el "Inicio", seguido por un "Registro de correo" donde el usuario proporciona una dirección de correo electrónico. Luego, el usuario recibe un correo de confirmación en la etapa "Recepción de correo" y procede a "Login con enlace", donde hace clic en un enlace para iniciar sesión en la plataforma. Una vez autenticado, el usuario llega a la etapa de "Captura de texto", donde puede ingresar el texto que necesita ser evaluado. El texto ingresado es procesado en la etapa de "Evaluación", donde algoritmos de PLN analizan el contenido para detectar indicadores de violencia de género. Este proceso puede incluir el análisis de palabras clave, frases y estructuras lingüísticas que comúnmente se asocian con la violencia de género. Finalmente, el flujo concluye con el "Fin", que podría indicar el fin del proceso de evaluación y probablemente la presentación de los resultados al usuario.




Figura 1 Funcionamiento de la aplicación web

El uso de PLN en este contexto permite una evaluación sistemática y automática de los textos, facilitando la identificación de contenido potencialmente dañino o peligroso que podría no ser fácilmente reconocido a simple vista.

Implementación

Para la detección de necesidades e identificación de la problemática se aplicó un cuestionario usando la herramienta de Google Forms, la cual fue aplicada a 174 estudiantes del Instituto Tecnológico de Tuxtla Gutiérrez. El objetivo principal de este paso fue identificar el porcentaje de víctimas de violencia, así como el tipo de violencia más recurrente.

En la Figura 2 se presentan los resultados obtenidos en una de las preguntas más importantes, donde se muestra que un 70% de ellas ha sufrido violencia.

¿Alguna vez has sufrido violencia?

174 respuestas




Figura 2 Víctimas de violencia



Otro dato importante era identificar el tipo de violencia o tipos, más frecuentes. Se observa en la Figura 3, con un 55% el tipo de violencia emocional o psicológico, y con un 33% violencia física.

¿Qué tipo de violencia has experimentado?

174 respuestas




Figura 3 Tipos de violencia

Así mismo para la construcción y ejecución de la fase 2, una de las actividades de suma relevancia fue recopilar frases que incluyeran violencia y no violencia para su uso en el modelado del algoritmo. Se recopilaron más de dos mil frases clasificadas entre positivas y negativas, se almacenaron en un base de datos CSV y algunas muestras se observan en la Figura 4 y 5, respectivamente. Estas frases fueron procesadas y usadas en el entrenamiento del modelo por 24 horas.

Frases

Archivo Editar Ver Insertar Formato Datos Herramientas Extensiones Ayuda

100% \$ % .0_ .00 123 Predet... - 10 + B I A

A1	A	B	C	D	E	F
1	Marca temporal	1. Frase positiva	2. Frase positiva	3. Frase positiva	4. Frase positiva	5. Frase positiva
2	27/2/2023 9:43:09	te amo	me gustas	eres especial	puedes lograrlo	ánimo
3	27/2/2023 10:05:58	Que te vaya excelente er	que tengas un día feliz	mucho éxito en tu exposición de	eres la persona mas increíble c	buenos días amor, que tengas un día
4	27/2/2023 10:11:10	Me gustas mucho	Eres bien chida	Disfruto cada momento a tu lado	Quiero estar contigo siempre	Te extraño
5	27/2/2023 17:14:06	Buen día ojitos hermosos:	Que tengas un excelente día	Que tengas muchos éxitos	Despierta que lograrás tus met	Que pases dulces sueños
6	27/2/2023 18:06:04	Hoy será un buen día	Me irá de maravilla en mi examen	Soy la mejor	Yo puedo con esto	Éxito en tu día
7	28/2/2023 8:33:22	Que tengas un excelente	¿Como estuvo tu día?	¿Llegaste bien a casa?	Te amo	Te quiero
8	28/2/2023 8:34:26	Excelente día chaparrita	Como amaneciste mi amorcito bonit	Te amo con todo mi corazón am	Eres lo más lindo de mi día te	Eres el más grande amor de mi vida
9	28/2/2023 8:36:40	Hola amorcito, Dios te be	Descansa mi vida, te amo!	Éxito en tu partido mi mvp, eres	Éxito y bendiciones en tu activ	Solo somos tú y yo♥
10	28/2/2023 8:38:12	Buenos días mi amor, qu	Eres muy inteligente, se que eres ce	Eres una gran niña, que siempre	Eres muy inteligente mi amor, f	Siempre que tengas un problema pue
11	28/2/2023 8:38:15	Confío en ti	Te quiero/amo	Puedes contar conmigo	Vamos a solucionarlo juntos	Me gusta tu compañía
12	28/2/2023 8:38:27	Estoy orgullosa de ti	Te amo mucho	Estaré para apoyarte y motivarte	Eres lo más bonito de mi vida	Todo estará bien, estoy aquí
13	28/2/2023 8:38:47	Que tengas un excelente	Orgullosa de tus pequeños y grande	Recuerda que es un mal día, no	Yo te echo porras desde lejitos,	Que bonito es verte cumplir tus metas
14	28/2/2023 8:39:08	Eres alguien muy capaz	Qué bonito es estar contigo.	Me gusta platicar contigo porque	Qué atractivo e interesante es	Me siento muy afortunada de tenerte
15	28/2/2023 8:39:25	-Suerte en tu examen an	-Felicidades mi amor, sabia que pod	-Te pienso en cada momento, te	Tengo ganas de 3 cosas: abraz	Te quiero mas que nada en este mun
16	28/2/2023 8:40:55	Buenos días hermosa!	Cómo amaneció la más guapa del te	Tú eres chingona!!	Siento una paz al hablar contigo	No se que me gusta mas, el Cruz azu
17	28/2/2023 8:41:36	Estoy muy orgullosa de t	Ante toda adversidad; estaré para ti	Gracias por tu compañía, desde	Que tengas buen día; recuerda	Eres mi lugar seguro
18	28/2/2023 8:42:01	Que tengas un bonito día	Recuerda desayunar guapo porque	Hoy mire las nubes y me record	Alguien día vamos a ver atarde	Nunca voy a olvidar ese día en el q n
19	28/2/2023 8:43:06	Buenos días cosita linda,	¿Qué haces amor? Te adoró y extra	La vida me ha regalado a un ser	El mejor regaló eres tú, no te q	Te deseo el mejor día de tu vida amo
20	28/2/2023 8:44:12	Gracias por quererme as	Te amo demasiado	Me gusta mucho pasar tiempo o	¿Ya casi vienes? Te cocine alg	Te amo con el alma
21	28/2/2023 8:44:14	Gracias por tu amor, que	haces mi mundo más bonito	que tengas un bonito día, amor	te extrañooooo	No es que tuviera mala suerte en el a
22	28/2/2023 8:46:26	Estoy muy orgullosa de t	Gracias por estar conmigo, te quier	Gracias por escucharme y apoy	Recuerda que estoy para ti aúr	Si yo pudiera darte una cosa en la vic
23	28/2/2023 8:46:37	Ten un bonito día, te am	Que bonita te ves hoy	Me gusta mucho ser la mejc	Que felicidad me da verte crec	Quiero volver a Tuxtla solamente par
24	28/2/2023 8:46:51	Eres una excelente perso	Linda noche cariño, te amo	Algun día cuando el amor	Recuerda que también puedes	Incluso si es por defecto, eres da

Respuestas de formulario 1

Figura 4 Base de datos con frases positivas



Frases

Archivo Editar Ver Insertar Formato Datos Herramientas Extensiones Ayuda

100% 123 Predet... 10 B I A

A1 Marca temporal

	A	B	C	D	E	F
1	Marca temporal	1. Frase positiva	2. Frase positiva	3. Frase positiva	4. Frase positiva	5. Frase positiva
2	27/2/2023 9:43:09	te amo	me gustas	eres especial	puedes lograrlo	ánimo
3	27/2/2023 10:05:58	Que te vaya excelente er	que tengas un día feliz	mucho éxito en tu exposición de	eres la persona mas increíble c	buenos días amor, que tengas un día
4	27/2/2023 10:11:10	Me gustas mucho	Eres bien chida	Disfruto cada momento a tu ladc	Quiero estar contigo siempre	Te extraño
5	27/2/2023 17:14:06	Buen día ojitos hermosos:	Que tengas un excelente día	Que tengas muchos éxitos	Despierta que lograrás tus met:	Que pases dulces sueños
6	27/2/2023 18:06:04	Hoy será un buen día	Me irá de maravilla en mi examen	Soy la mejor	Yo puedo con esto	Éxito en tu día
7	28/2/2023 8:33:22	Que tengas un excelente	¿Como estuvo tu día?	¿Llegaste bien a casa?	Te amo	Te quiero
8	28/2/2023 8:34:26	Excelente día chaparrita	Como amaneciste mi amorcito bonit	Te amo con todo mi corazón am	Eres lo más lindo de mi día te	Eres el más grande amor de mi vida
9	28/2/2023 8:36:40	Hola amorcito, Dios te be	Descansa mi vida, te amo!	Éxito en tu partido mi mvp, eres	Éxito y bendiciones en tus activ	Solo somos tú y yo♥
10	28/2/2023 8:38:12	Buenos días mi amor, qu	Eres muy inteligente, se que eres ce	Eres una gran niña, que siempre	Eres muy inteligente mi amor, f	Siempre que tengas un problema pue
11	28/2/2023 8:38:15	Confío en ti	Te quiero/amo	Puedes contar conmigo	Vamos a solucionarlo juntos	Me gusta tu compañía
12	28/2/2023 8:38:27	Estoy orgullosa de ti	Te amo mucho	Estaré para apoyarte y motivarte	Eres lo más bonito de mi vida	Todo estará bien, estoy aquí
13	28/2/2023 8:38:47	Que tengas un excelente	Orgullosa de tus pequeños y grande	Recuerda que es un mal día, no	Yo te echo porras desde lejitos,	Que bonito es verte cumplir tus metas
14	28/2/2023 8:39:08	Eres alguien muy capaz	Qué bonito es estar contigo.	Me gusta platicar contigo porque	Qué atractivo e interesante es i	Me siento muy afortunada de tenerte
15	28/2/2023 8:39:25	-Suerte en tu examen an	-Felicidades mi amor, sabia que pod	-Te pienso en cada momento, te	Tengo ganas de 3 cosas: abraz	Te quiero mas que nada en este mun
16	28/2/2023 8:40:55	Buenos días hermosa!	Cómo amaneció la más guapa del te	Tú eres chingona!!	Siento una paz al hablar contig	No se que me gusta mas, el Cruz azu
17	28/2/2023 8:41:36	Estoy muy orgullosa de t	Ante toda adversidad; estaré para ti	Gracias por tu compañía, desde	Que tengas buen día; recuerda	Eres mi lugar seguro
18	28/2/2023 8:42:01	Que tengas un bonito día	Recuerda desayunar guapo porque	Hoy mire las nubes y me record	Alguien día vamos a ver atarde	Nunca voy a olvidar ese día en el q n
19	28/2/2023 8:43:06	Buenos días cosita linda,	¿Qué haces amor? Te adoró y extra	La vida me ha regalado a un ser	El mejor regalo eres tú, no te q	Te deseo el mejor día de tu vida amo
20	28/2/2023 8:44:12	Gracias por quererme as	Te amo demasiado	Me gusta mucho pasar tiempo o	¿Ya casi vienes? Te cocine algi	Te amo con el alma
21	28/2/2023 8:44:14	Gracias por tu amor, que	haces mi mundo más bonito	que tengas un bonito dia, amor	te extrafoooo	No es que tuviera mala suerte en el a
22	28/2/2023 8:46:26	Estoy muy orgullosa de t	Gracias por estar conmigo, te quier	Gracias por escucharme y apoy	Recuerda que estoy para ti aúr	Si yo pudiera darte una cosa en la vic
23	28/2/2023 8:46:37	Ten un bonito día, te amc	Que bonita te ves hoy	te duele la cintura de ser la mejc	Que felicidad me da verte crecc	Quiero volver a Tuxtla solamente par
24	28/2/2023 8:46:54	Eres una excelente perso	Linda noche cariño, te amo	Alguien puede romperte el cora	Recuerda que también puedes	Incluso si es con perfecta, eres de

+ Respuestas de formulario 1

Figura 5 Base de datos con frases negativas

Al obtener el algoritmo en funcionamiento, se pasó al desarrollo de la interfaz para el usuario. Esta es una página web funcional que permite que el usuario ingrese frases para evaluarlas.

El proyecto pasó por distintos niveles de monitoreo, donde se segmentó el tipo de público a quien será dirigido Violencia Cero. Los usuarios son personas que buscan información asesorada por expertos. Al llegar a un nivel TLR 7 de los Niveles de Madurez Tecnológica (Figura 6), este proyecto se ha probado en con usuarios públicos dentro del Instituto Tecnológico de Tuxtla Gutiérrez.



Nivel de Madurez Tecnológica Actual



Figura 6 Nivel de madurez tecnológica

Resultados

Mediante el desarrollo del proyecto se obtuvieron resultados significativos, desde el análisis del porcentaje de estudiantes encuestados en el Instituto Tecnológico de Tuxtla Gutiérrez que han experimentado violencia por lo menos una vez en su vida. De la muestra total, siendo esta de 174 estudiantes, el 70% identificó haber experimentado violencia, esto da un resultado de 121 personas víctimas de violencia. Así mismo es importante destacar que la violencia más recurrente es del tipo emocional, ocupando segundo lugar la violencia física y tercer lugar la violencia sexual, como se mostró en gráficas anteriores. Con base en el sustento anterior se llevó a cabo el modelado del algoritmo y entrenamiento de frases mediante el procesamiento del lenguaje natural de textos. Esto para el desarrollo de una interfaz funcional que sea una herramienta de apoyo en la detección de violencia en textos, se observa en la imagen 8 la plataforma web “Violencia Cero” mediante el enlace <https://violenciacero.app/>.

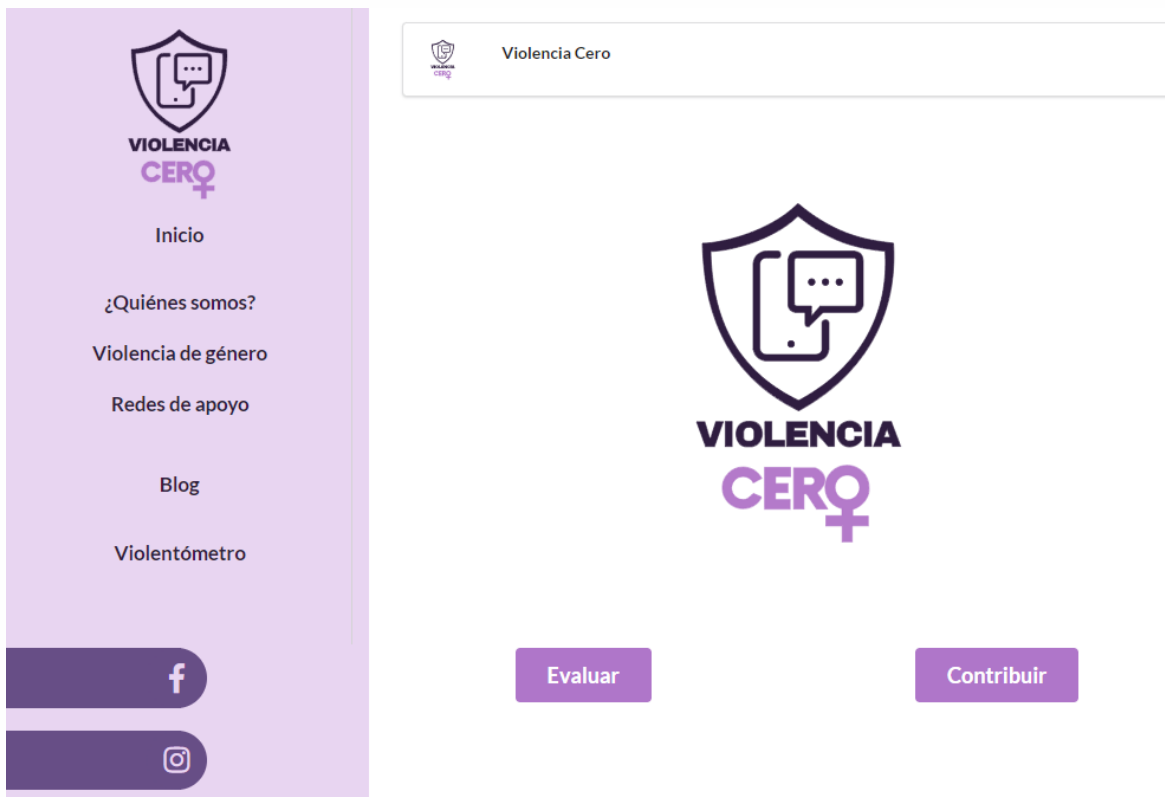


Figura 7 Plataforma Web

Cabe mencionar que la plataforma se encuentra en funcionamiento, y actualmente es de uso libre. Permite la evaluación de frases, así como la contribución al proyecto. Este último punto permite que personas externas colaboren enviando frases para su procesamiento o bien, evaluando algunas de estas frases, con el fin de ampliar la base de datos que el equipo maneja y con ello agregar todo tipo de frases coloquiales.

En la Figura 8, se muestra un ejemplo de evaluación de una frase positiva, mientras que en la Figura 9 se presenta la evaluación de una frase negativa.



Evalua un texto

te odio, eres la basura del tec

Evaluar



 **Negativo** te odio, eres la basura del tec

Figura 8 Evaluación negativa



Evalua un texto

Que tengas un buen día

Evaluar


 **Positivo** Que tengas un buen día

Figura 9 Evaluación positiva

Además, este desarrollo permite realizar el análisis y evaluación de frases en español, frases que se dicen comúnmente en la región y mensajes de texto escritos incluso de manera abreviada.




Figura 10 Funcionamiento del entrenamiento

En la imagen 10 se presenta la evaluación realizada al software desarrollado, del lado izquierdo se muestra la exactitud que tiene al evaluar frases, la cual presenta un nivel alto; mientras que del lado derecho se analizó el nivel de errores, como se observa en este



parámetro, los errores del entrenamiento han disminuido y la tendencia es que continúen bajando de acuerdo.

Conclusión

El trabajo desarrollado se ha implementado una aplicación web para la detección de la violencia de género, particularmente entre la comunidad estudiantil del Instituto Tecnológico de Tuxtla Gutiérrez. A través de una encuesta aplicada a una muestra de 174 estudiantes, se identificó que un alarmante 70% había experimentado algún tipo de violencia, sumando un total de 121 personas afectadas. Los datos recabados ilustran que la violencia emocional es la más prevalente, seguida por la física y la sexual.

Basándose en estos hallazgos, se procedió al modelado de un algoritmo sofisticado, capaz de procesar el lenguaje natural para detectar indicios de violencia en textos. Este proceso culminó con la creación de la plataforma web "Violencia Cero", una interfaz funcional que no solo evalúa frases, sino que también permite la colaboración externa. Los usuarios pueden contribuir al enriquecimiento de la base de datos del proyecto, proporcionando o evaluando frases que ayudan a refinar el modelo.

La eficacia del software es evidente, con la precisión en la evaluación de frases demostrando ser alta y un marcado descenso en los errores de entrenamiento, lo que indica una tendencia positiva hacia la mejora continua. Este desarrollo es significativo no solo por su aplicabilidad técnica, sino también por su relevancia social, al ofrecer una herramienta de apoyo crucial en la lucha contra la violencia de género. La capacidad de analizar y evaluar frases en español, especialmente aquellas comunes en la región y mensajes de texto incluso en su forma abreviada, refuerza la importancia y versatilidad de la plataforma.

El proyecto "Violencia Cero" se dispone a ser una iniciativa pionera en su enfoque técnico para abordar un problema social grave. La plataforma no solo ha demostrado ser una herramienta útil en la detección de violencia de género en la comunicación escrita, sino que también actúa como un catalizador para una mayor conciencia y acción comunitaria. Con la participación activa y la colaboración continua, la tendencia hacia la minimización de la violencia de género parece prometedora y es un testamento de cómo la tecnología puede ser empleada para generar cambios sociales positivos.

Agradecimientos

Se hace el agradecimiento al Instituto de Ciencia, Tecnología e Innovación de Chiapas, por el financiamiento del proyecto a través del programa APOYOS ÚNICOS OTORGADOS A LOS INTEGRANTES DEL SISTEMA ESTATAL DE INVESTIGADORES 2023.



Referencias

- Monge, E., & Kitze, D. (2019). Violencia sexual contra las mujeres: análisis de los parámetros y la perspectiva de género de los jueces en México. <http://repositorio-digital.cide.edu//handle/11651/3875>
- Sánchez-Vera, M. del M., & González-Martínez, J. (2019). Pensamiento computacional, Robótica y Programación en educación: Computational Thinking, Robotics and Coding in Education. *Revista interuniversitaria de investigación en tecnología educativa*. <https://doi.org/10.6018/riite.407731>
- Velázquez, M. M. (2022). Movimiento feminista versus Estado androcéntrico. Una disputa entre historia y memoria en México. *Revista Temas Sociológicos*, (30), 419-460.
- Mata-Santel, J., Luna-Gijón, G., & Ronquillo-Bolaños, A. (2023). Análisis de notas periódicas sobre violencia contra las mujeres mediante estrategias de gestión de datos desde el diseño de información. *Acta Universitaria*, 33, 1–17.



Sistema IoT para la detección de armas utilizando el área de detección como umbral de seguridad.

Gilbert F. Pérez-García,¹ María C. Salgado-Gutiérrez,¹ Alexis de Jesús, Flores-García,² Elías N Escobar-Gómez,³

¹ Departamento de Ciencias Básicas, Tecnológico Nacional de México, I. T. de Tuxtla Gutiérrez, 29050, Tuxtla Gutiérrez, Chiapas. México.

² Departamento de Eléctrica y electrónica, Tecnológico Nacional de México, I. T. de Tuxtla Gutiérrez, 29050, Tuxtla Gutiérrez, Chiapas. México.

³ Departamento de Ingeniería Industrial, Tecnológico Nacional de México, I. T. de Tuxtla Gutiérrez, 29050, Tuxtla Gutiérrez, Chiapas. México.

gilbert.pg@tuxtla.tecnm.mx (G.F.P.-G.); alexis.fg@tuxtla.tecnm.mx (A.J.F.-G.);
maria.sg@tuxtla.tecnm.mx (M.C.S.-G.); enescobarg@tuxtla.tecnm.mx (E. N. E.-G).

Resumen

Un sistema de visión artificial utiliza cámaras de video para la extracción de información del mundo real, es importante tener en cuenta que, durante este proceso, hay factores externos que pueden introducir ruido en los fotogramas capturados, tales como cambios inesperados en la iluminación o la presencia de objetos con formas similares al objeto de interés, lo que podría generar detecciones incorrectas. Considerando este hecho, en este trabajo se propone un sistema de visión artificial que permita la detección de armas en un área de interés y a su vez incorpore un factor de seguridad basado en un umbral de referencia. Este umbral solamente consideraría como detecciones positivas aquellas predicciones que caen por debajo del límite predefinido. El modelo neuronal desarrollado cuenta con una precisión del 96.3%, una sensibilidad del 95%, un promedio de precisión media (mpA) del 98.2%, y un puntaje F1



del 96%, con un factor de confianza de 0.462. El sistema se complementa con un módulo de transmisión remota que escanea en tiempo real el área bajo vigilancia.

Este módulo envía imágenes a una base de datos centralizada para mantener registros históricos y muestra información a través de una aplicación web.

Palabras clave: Detección de armas, YOLOv8, visión artificial, aprendizaje profundo, redes neuronales convolucionales, umbral de calibración.

Introducción

En la actualidad, la seguridad pública continúa siendo un tema de gran importancia, especialmente con la expansión de las ciudades y la creciente complejidad de sus entornos. Este crecimiento ha provocado un aumento en los delitos, particularmente aquellos que involucran el uso de armas de fuego, lo que afecta significativamente la seguridad de los ciudadanos. Las estadísticas muestran un preocupante incremento en los asaltos armados en los últimos años [1]. Por lo tanto, existe una necesidad urgente de herramientas efectivas que puedan detectar y responder rápidamente a situaciones críticas, lo que ha llevado a la búsqueda de soluciones que integren tecnologías avanzadas [2,3,4].

En este contexto, la visión por computadora ha surgido como una opción viable para abordar este problema [5,6, 7]. Sin embargo, al utilizar una videocámara para monitorear la escena, es crucial considerar que varios factores externos podrían interferir durante la vigilancia. Por lo tanto, no solo es necesario desarrollar un modelo con una precisión excelente, sino también explorar formas de minimizar el ruido introducido por la videocámara. En este sentido, se hace indispensable la introducción de factores de seguridad o métodos de corrección confiables que no demanden recursos excesivos, especialmente en un sistema de detección en tiempo real.

En la literatura, diversos autores han abordado este tema con enfoques variados [8] en cuanto a complejidad y consumo de recursos. Una técnica comúnmente empleada es el preprocesamiento de imágenes, que busca mejorar la calidad y claridad de las capturas. Este



proceso incluye correcciones de saturación, nitidez y brillo, adaptadas a las características específicas del objeto y las condiciones de iluminación [9]. Otros investigadores han implementado técnicas más avanzadas [8-12]. Por ejemplo, en [13], se combina el algoritmo de detección YOLOv3 con un algoritmo de detección de postura para lograr una precisión del

79%, una sensibilidad del 59% y una precisión promedio del 61%, considerando la postura típica al empuñar un arma, de la misma manera que lo trabajan en [14,15]. Otros autores utilizan la métrica IoU [16] (Intersección sobre Unión) para reducir falsos positivos al evaluar la coincidencia de detecciones, aunque no se especifica las métricas resultantes del modelo. En [17], además de la detección de armas de fuego, los autores calculan la distancia entre la cámara y el objeto utilizando visión estéreo, lo que añade un parámetro extra y logra una precisión del 92.2% con un error de 9.3 cm dentro de un rango de hasta 3 metros.

En resumen, aunque los sistemas de visión artificial han tenido una amplia aplicación en diversos campos [18,19,20], es crucial abordar las interferencias causadas por las imágenes capturadas por la videocámara. En este estudio, se plantea el desarrollo de un sistema modular capaz de detectar armas de fuego de cañón corto en tiempo real. Como medida de seguridad para las imágenes capturadas, se propone la utilización de un umbral que se basa en la medición del área de las detecciones. Se considerarán como detecciones válidas únicamente aquellas que estén por debajo de este umbral, con el objetivo de minimizar los falsos positivos al descartar detecciones cuyo tamaño supere el umbral y que se asemejen a objetos grandes y similares en forma al objeto de interés. El sistema integra tecnología IoT para transmitir las predicciones de manera remota hacia un servidor en la nube. Además, se habilita la visualización de las detecciones a través de una página web en cada instancia de detección.

Las contribuciones de este trabajo son las siguientes:

- 1.- Conjunto de datos público modificado mediante imágenes recopiladas de fuentes en línea y de simulaciones propias. Este conjunto de datos contiene 9559 imágenes de armas de fuego de cañón corto.
- 2.- Generación de un modelo predictivo con excelentes métricas, exhibiendo una precisión del 96.3%, una sensibilidad del 95%, un mAP del 98.2% y un factor F1 del 96% con un factor de confianza de ser correcto del 0.462.



- 3.- Se establece una metodología para la implementación del umbral de seguridad basado en el área de las detecciones
- 4.- Se implementa un sistema de transmisión y recopilación de información a través de un servidor y una interfaz web. Además de la electrónica necesaria para la implementación de alarmas cada vez que se actualiza una detección potencial.

Materiales y métodos

Metodología general

El sistema propuesto está basado principalmente en una red neuronal convolucional pre-entrenada conocida como Darknet. La extracción de características se realiza mediante el algoritmo de Yolo en su versión 8. El entrenamiento de la red se realiza mediante la transferencia de conocimiento utilizando un conjunto de datos de dominio público modificado por imágenes propias e imágenes descargas de internet. En esta sección se describe la metodología implementada para la realización del sistema propuesto (Figura 1).




Figura 1. Metodología general del sistema propuesto.

Sistema propuesto

Para la adquisición de imágenes, se utilizó una cámara de video inalámbrica con una resolución de 920 píxeles. Cuenta con capacidades de visión nocturna infrarroja y tiene un campo de visión horizontal de 360 grados, un campo de visión vertical de 115 grados y un ángulo de apertura de 100.4°. Se recomienda instalar las cámaras en una perspectiva desde arriba para maximizar el campo de visión en el área de interés, como se ilustra en la Figura 2. Aunque no es estrictamente necesario, se recomienda el uso de cámaras con conectividad inalámbrica, ya que elimina la necesidad de extensos cables hacia la computadora de placa única y permite el almacenamiento directo de datos en la base de datos. Las imágenes se capturaron a una resolución de 640 píxeles.




Figura 2. Distribución especial de la escena bajo vigilancia.

Conjunto de datos

Como se muestra en la Figura 3, el conjunto de datos utilizado comprende de dos partes distintas: a) imágenes adquiridas de fuentes en línea y b) un conjunto de datos propio. Para la selección de imágenes, se establecieron criterios específicos con respecto al objeto de interés, como tamaño, ángulo de posición, color en las imágenes, imágenes centradas o dentro de una escena de acción, sujetos de diferentes géneros y edades. El etiquetado (formato YOLOv8) se llevó a cabo utilizando cuadros delimitadores utilizando Python, lo que permitió la extracción y el almacenamiento de coordenadas en archivos de texto separados. Se utilizó una sola etiqueta de clase, llamada 'arma', indexada como 0. Cada una de estas coordenadas está relacionada con el tamaño de imagen original, por lo que es esencial normalizarlas a una dimensión de imagen de 1x1 píxel. En total, el conjunto de datos utilizado en este trabajo consta de 9559 imágenes, divididas en un 80% (7647 imágenes) para entrenamiento, un 10% (956 imágenes) para validación y un 10% (956 imágenes) para pruebas. La selección se realizó meticulosamente para garantizar el equilibrio y la neutralidad del conjunto de datos.



Figura 3. Conjunto de datos. a) Fuente propia b) Fuente de internet.



Entrenamiento del modelo

Para la estructura de aprendizaje, se utilizó la red neuronal Darknet empleando un proceso de optimización de pesos utilizando el algoritmo de Descenso de Gradiente Estocástico (SGD, por sus siglas en inglés). Se establecieron los siguientes parámetros iniciales del modelo: Número de épocas de entrenamiento (epochs = 40), tamaño del lote para el análisis simultáneo de imágenes (batch = 10), ratio de Intersección sobre Unión (IoU) entre cuadros delimitadores

(iou = 0.7), tasas de aprendizaje inicial y final (lr0 = lrf = 0.01), tamaño de redimensionamiento de la imagen en píxeles (image_size = 640), resumidos en la Tabla 1. Durante el entrenamiento, la imagen se dividió en regiones iguales. Una matriz recorrió toda la imagen, aplicando operaciones de convolución en cada iteración, lo que permitió la extracción de un vector de características, posteriormente utilizado para las predicciones.

Tabla 1. Parámetros configurados

Parámetro	Valor
Época	40
Tamaño Lote	10
IoU	0.7
lr0	0.01
lr1	0.01
Tamaño Imagen	640

Se llevó a cabo un proceso de ponderación para cada predicción basado en probabilidades calculadas previamente. Esta ponderación implicó las primeras 20 capas convolucionales, seguidas de una capa de normalización. Durante la etapa de implementación, se introdujeron 4 capas convolucionales y 2 capas conectadas con pesos inicializados aleatoriamente. La capa final de la red procesó información de las capas precedentes, utilizando la función de pérdida para comparar la salida obtenida con las coordenadas correctas del cuadro delimitador. El optimizador ajustó los pesos del modelo en función de la cantidad de error, reduciendo así los errores en el ciclo subsiguiente. El proceso de entrenamiento se llevó a cabo utilizando



YOLOv8.0.20 con una GPU en un entorno configurado con Python-3.10.12, torch-2.1.0+cu118 y CUDA:0 (Tesla T4, 15102MiB). El sistema informático constaba de 2 CPUs con 12.7 GB de RAM y tenía un espacio en disco de 27.1/78.2 GB disponible.

Umbral de calibración

Durante la fase de implementación del sistema, se observó que las cajas de detección positiva comparten un área común dentro de un rango específico, lo cual es un hallazgo importante para la optimización del modelo. Para comprender mejor este fenómeno, se llevó a cabo un estudio detallado de esta área común.

Para ello, se ubicó a un sujeto sosteniendo un arma de fuego en diferentes ubicaciones estratégicas (consulte la Figura 4). A través de programación, se extrajo el tamaño de cada una de las detecciones identificadas, lo que proporcionó información crucial para ajustar y mejorar el rendimiento del sistema.




Figura 4. a) Escenario propuesto del análisis del umbral, b) Dimensiones del escenario c) Distancia desde la posición marcada hacia la cámara.

El estudio implica la recreación de una escena en un área específica, cuyas dimensiones se detallan en la Figura 4-b. Se colocó a una persona en cuatro ubicaciones diferentes, cada una a una distancia específica de la cámara, como se muestra en la Figura 4-c. Se calcularon los tamaños de las áreas detectadas para cada posición específica, y se estableció el valor de umbral considerando el área máxima detectada, como se muestra en la Figura 5. Esta medida será considerada como un factor de seguridad adicional; las detecciones que superen esta referencia serán rechazadas para reducir las detecciones falsas con objetos de forma similar que presenten áreas más grandes.



Figura 5. Extracción del umbral a) posición i, b) posición ii, c) posición iii, d) posición iv.

Las posiciones a), b), c) y d) en cada cuadro de la Figura 5 corresponden a las identificadas en la Figura 4-a, etiquetadas como i, ii, iii, iv, respectivamente. Al analizar la ubicación del sujeto de acuerdo con estas identificaciones, se observó que el tamaño de las áreas detectadas variaba entre $4.37E-4$ y $3.72E-3$ unidades arbitrarias (u.a.). Basándonos en este análisis, se ha establecido un umbral que permita áreas más pequeñas que $4E-3$ unidades arbitrarias como límite aceptable para la detección de objetos de interés. Esta determinación del umbral se justifica porque, en situaciones reales, se esperaría que las áreas de detección caigan dentro del rango mencionado.

Sistema IoT

El modelo entrenado se ejecutó en una computadora monoplaca llamada Orange Pi 5, equipada con un procesador Rockchip que opera a una frecuencia de 2.4 GHz y con 16 GB de RAM. Esta máquina incluye un módulo Wifi+BT para habilitar la conexión inalámbrica con la cámara IP. El diagrama utilizado para la implementación del sistema se presenta en la Figura 6.

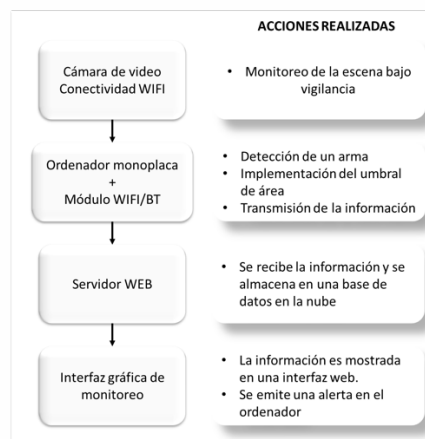


Figura 6. Diagrama de bloques del sistema físico propuesto.



El sistema recibe como entrada una serie de fotogramas de la escena bajo vigilancia, el algoritmo para establecer la conexión con la cámara WiFi se programó en python, el modelo entrenado analiza cada fotograma para identificar la presencia de un arma en la escena mediante un cuadro de predicción. Junto con este script, se incluyeron otros que contienen la lógica para verificar el umbral establecido para el área de los cuadros de predicción. Esta verificación es crucial para aceptar únicamente aquellas predicciones con un área por debajo del valor de umbral establecido (Figura 7).

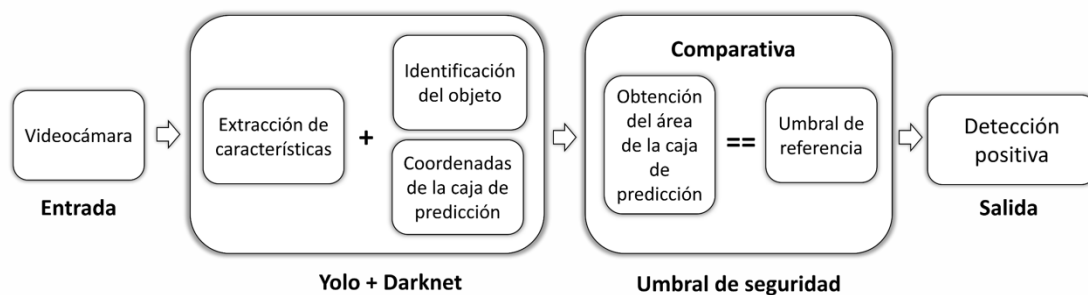


Figura 7. Metodología de detección.

Para la transmisión de datos al servidor web, se implementó un script utilizando el método POST. Este método permite la transferencia discreta e invisible de datos en la URL, asegurando la privacidad de la información. La recepción de esta información se llevó a cabo mediante scripts programados en PHP, Javascript y AJAX. PHP desempeña un papel fundamental en la lectura de las entradas de los métodos POST. Cada vez que recibe un código POST, el script PHP procesa la información, incluyendo una captura de la escena detectada, las coordenadas de detección en la captura, el área del cuadro de detección, así como la fecha y hora de la detección. Esta información se muestra en pantalla a través de una página HTML scriptada.

Para proporcionar dinamismo a la página web, se empleó la técnica de desarrollo web conocida como AJAX, que permite la creación de aplicaciones web asíncronas.



Esta implementación se ejecuta en los navegadores de los usuarios, manteniendo una comunicación asíncrona con el servidor en segundo plano, lo que mejora la interactividad y la experiencia del usuario.

Resultados

Training

En esta sección, se presentan los resultados obtenidos del proceso de aprendizaje, mostrando gráficos generados y explicando el análisis llevado a cabo en un entorno simulado del mundo real respecto a las predicciones realizadas. El enfoque se centra en evaluar la efectividad del sistema en varios aspectos clave. En primer lugar, se evaluó la Curva de Precisión-sensibilidad, proporcionando información sobre la efectividad del modelo basado en el área bajo la curva. Posteriormente, se utilizó el puntaje F1 para analizar el rendimiento del modelo, identificando el nivel de confianza óptimo donde las métricas de precisión y sensibilidad están balanceadas. Finalmente, se incluyó el análisis de la Precisión Promedio (mAP), ofreciendo detalles sobre la precisión general del modelo. El gráfico de Precisión-Sensibilidad se representa en la Figura 8. Se observa que este modelo alcanza aproximadamente un 100% de precisión y un 100% de sensibilidad. El área bajo la curva, con un valor de 0.983, indica un equilibrio satisfactorio entre ambos parámetros.

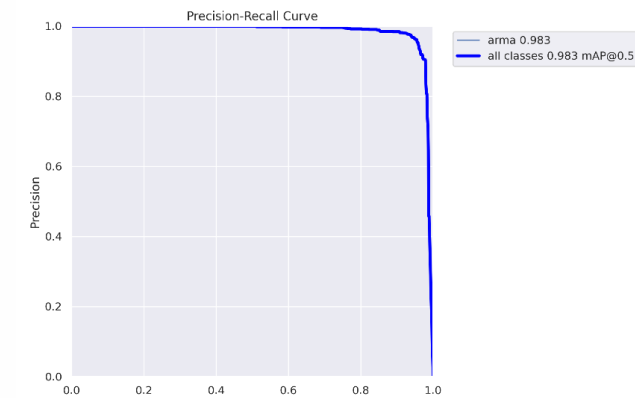


Figura 8. Curva Precisión - Sensibilidad

El nivel de confianza de las predicciones del sistema se determinó utilizando el puntaje F1. A medida que este nivel de confianza aumenta, también aumenta la probabilidad de que la predicción sea un verdadero positivo. En nuestro modelo, la confianza alcanza un valor de 0.462 con un puntaje F1 de 0.96. En este punto de confianza específico, se puede afirmar que tanto la precisión como la sensibilidad están equilibrados, como se ilustra en la Figura 9.




Figura 9. Curva de confianza de la métrica F1

La Figura 10 representa el gráfico específico relacionado únicamente con la precisión. En el contexto de nuestro estudio, se observa que al establecer un umbral de confianza igual o superior a 0.922, se logra una precisión del 100%. Esto sugiere que, al seleccionar este umbral, se garantiza la detección de armas con una fiabilidad del 100%.




Figura 10. Curva del factor Precisión – confianza.

Sin embargo, al considerar el parámetro de sensibilidad, la Figura 11 ilustra que a medida que aumentan los valores del umbral de confianza, la sensibilidad disminuye. Esta tendencia indica que podríamos perder algunas predicciones positivas, lo que, a su vez, reduciría la probabilidad de errores en las predicciones. Los gráficos analizados confirman lo observado en la Figura 9, donde la métrica F1 establece un umbral de 0.462 en el que tanto la precisión como la sensibilidad están balanceados.

En resumen, los datos obtenidos de las métricas se presentan en la Tabla 2, mostrando los valores de precisión (P), sensibilidad (R) y mAP. Este último parámetro indica que la precisión del sistema es del 98.2% con una confianza de 0.5 o superior y del 84.265% con una confianza de 0.95 o superior.




Figura 11. Curva sensibilidad - confianza

Tabla 2. Resultados de entrenamiento

Época	mAP_0.5	mAP_0.95	Precisión	Recuperación	Cls_Loss
1	0.87267	0.64791	0.81884	0.80731	0.80535
40	0.98271	0.84265	0.96328	0.95068	0.32697



Implementación

En la Figura 12 se presentan varias imágenes donde se utilizó el modelo para realizar predicciones. Estas imágenes muestran a un hombre utilizando un arma de fuego desde varios ángulos y en entornos con diferentes niveles de iluminación. Aunque el modelo fue diseñado para detectar en ubicaciones interiores bien iluminadas, logró predecir con precisión incluso en escenarios exteriores y de poca luz.




Figura 12. Implementación del modelo entrenado a) Entrada de la imagen, b) Salida de la imagen.

Finalmente, la Figura 13 muestra el diseño utilizado para la interfaz web. Cada vez que se detecta algo en la pantalla, se muestra una imagen de la escena capturada y se activa una alarma, lo que hace que el fondo parpadee en rojo, junto con una alarma audible. La interfaz está dividida en dos secciones principales:

Historial de Detecciones: Ubicada en el lado izquierdo, esta sección registra todas las detecciones realizadas y las organiza en orden descendente según la fecha de entrada.

Sistema de Monitoreo: En el lado derecho, se muestra la escena capturada. Es en esta sección donde se muestra la alarma visual con el fondo parpadeando en rojo.

Este diseño de interfaz proporciona una forma clara y organizada de visualizar las detecciones y monitorear las escenas capturadas en tiempo real.

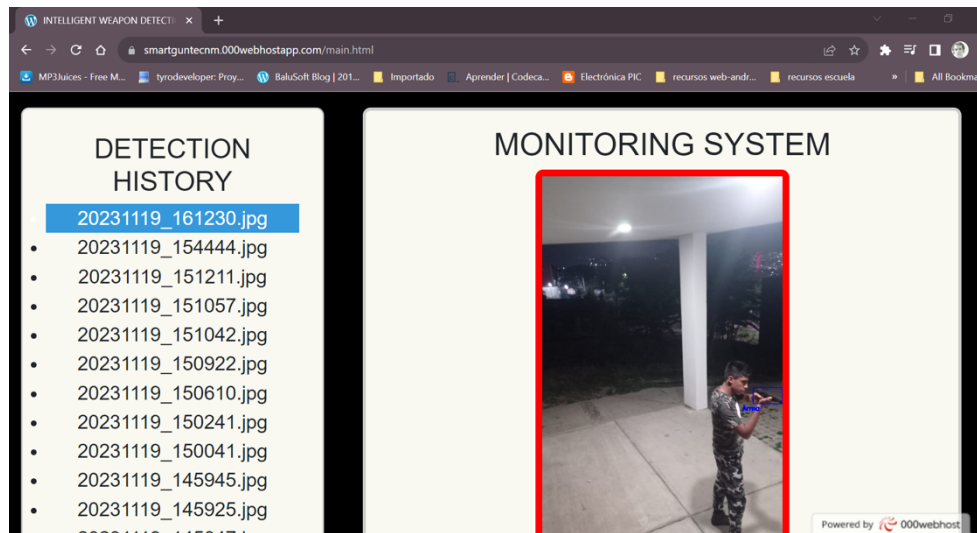


Figura 13. Interfaz WEB para el monitoreo y alarmas de la detección.

Conclusiones

Este estudio detalla exhaustivamente una metodología centrada en la detección precisa de armas, logrando una notable precisión del 96.3% con el modelo entrenado. Las contribuciones presentadas han sido fundamentales en la optimización del sistema de detección. Un elemento clave fue la selección meticulosa y la ampliación del conjunto de datos, lo que permitió una mejor extracción de características relacionadas con el objeto de interés.

La introducción de un umbral de calibración ha sido crucial para reducir las detecciones falsas, especialmente aquellas que exceden el área establecida. Esta elección se justifica al reconocer que las detecciones consistentes en la realidad están limitadas a ciertos rangos. La utilización integral de herramientas desarrolladas y scripts asociados para implementar la tecnología IoT representa un avance significativo, permitiendo el monitoreo en tiempo real y la notificación inmediata a las autoridades de seguridad pertinentes.

En resumen, este trabajo subraya la importancia crucial de la tecnología en la detección de armas, demostrando cómo la combinación de algoritmos avanzados, redes neuronales y sistemas de transmisión instantánea mejora la efectividad de los sistemas de seguridad. Sin embargo, persisten desafíos en lograr una detección infalible en cualquier contexto. Este estudio proporciona un marco sólido para futuras mejoras, destacando la necesidad continua de investigación y desarrollo en esta área para garantizar sistemas de detección más robustos y adaptables para diversas situaciones.



Referencias

- [1] Weigend Vargas, E., & Villarreal González, S. (2020). Firearms and injuries during home Robberies in Mexico, 2010–2017. *Trends in Organized Crime*, 1-24.
- [2] Álvarez-García, J. A., Salazar-González, J. L., Suarez, O. D., & Santaquiteria-Alegre, J. R. (2021, September). Vision and crowdsensing technology for an optimal response in security: Project results. In *2021 IEEE International Mediterranean Conference on Communications and Networking (MeditCom)* (pp. 82-87). IEEE.
- [3] Zou, Z., Chen, K., Shi, Z., Guo, Y., & Ye, J. (2023). Object detection in 20 years: A survey. *Proceedings of the IEEE*.
- [4] Moura, N. S., Gondim, J. M., Claro, D. B., Souza, M., & de Cerqueira Figueiredo, R. (2021, November). Detection of weapon possession and fire in public safety surveillance cameras. In *Anais do XVIII Encontro Nacional de Inteligência Artificial e Computacional* (pp. 290-301). SBC.
- [5] DO CT OR OF, P. E. (1961). *MACHINE PERCEPTION OF THREE-DIMENSIONAL, SO LIDS* (Doctoral dissertation, MASSACHUSETTS INSTITUTE OF TECHNOLOGY).
- [6] Sultana, F., Sufian, A., & Dutta, P. (2020). A review of object detection models based on convolutional neural network. *Intelligent computing: image processing based applications*, 1-16.
- [7] Jiang, P., Ergu, D., Liu, F., Cai, Y., & Ma, B. (2022). A Review of Yolo algorithm developments. *Procedia Computer Science*, 199, 1066-1073.
- [8] Jain, A., & Garg, G. (2020, August). Gun detection with model and type recognition using haar cascade classifier. In *2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)* (pp. 419-423). IEEE.
- [9] Castillo, A., Tabik, S., Pérez, F., Olmos, R., & Herrera, F. (2019). Brightness guided preprocessing for automatic cold steel weapon detection in surveillance videos with deep learning. *Neurocomputing*, 330, 151-161.
- [8] Fernandez-Carrobles, M. M., Deniz, O., & Maroto, F. (2019, July). Gun and knife detection based on faster R-CNN for video surveillance. In *Iberian conference on pattern recognition and image analysis* (pp. 441-452). Cham: Springer International Publishing.



- [9] González, J. L. S., Zaccaro, C., Álvarez-García, J. A., Morillo, L. M. S., & Caparrini, F. S. (2020). Real-time gun detection in CCTV: An open problem. *Neural networks*, 132, 297-308.
- [10] Zou, X. (2019, August). A review of object detection techniques. In 2019 International conference on smart grid and electrical automation (ICSGEA) (pp. 251-254). IEEE.
- [11] Nanda, S. K., Ghai, D., & Ingole, P. (2022). Analysis of Video Forensics System for Detection of Gun, Mask and Anomaly Using Soft Computing Techniques. *Journal of Cyber Security and Mobility*, 549-574.
- [12] Kalla, K., & Suma, G. J. (2022). Weapon Detection in Surveillance Videos Using Human Inspired Particle Swarm Optimization Algorithm and Support Vector Machine. *International Journal of Intelligent Engineering & Systems*, 15(4).
- [13] Ruiz-Santaquiteria, J., Velasco-Mata, A., Vallez, N., Bueno, G., Alvarez-Garcia, J. A., & Deniz, O. (2021). Handgun detection using combined human pose and weapon appearance. *IEEE Access*, 9, 123815-123826.
- [14] Pullakandam, M., Loya, K., Salota, P., Yanamala, R. M. R., & Javvaji, P. K. (2023, June). Weapon Object Detection Using Quantized YOLOv8. In 2023 5th International Conference on Energy, Power and Environment: Towards Flexible Green Energy Technologies (ICEPE) (pp. 1-5). IEEE.
- [15] Velasco-Mata, A., Ruiz-Santaquiteria, J., Vallez, N., & Deniz, O. (2021). Using human pose information for handgun detection. *Neural Computing and Applications*, 33(24), 17273-17286.
- [16] Iqbal, J., Munir, M. A., Mahmood, A., Ali, A. R., & Ali, M. (2019). Orientation aware object detection with application to firearms. *arXiv preprint arXiv:1904.10032*, 22.
- [17] Schcolnik-Elias, A., Martínez-Díaz, S., Luna-Taylor, J. E., & Castro-Liera, I. (2023). Detección de armas tipo pistola mediante el uso de redes convolucionales con una arquitectura tipo YOLO y estereoscopia. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 11(Especial2), 196-204.
- [18] KU, F. S., & Suguna, M. (2023, August). Subduing Crime and Threat in Real-Time by Detecting Weapons Using Yolov8. In 2023 International Conference on Circuit Power and Computing Technologies (ICCPCT) (pp. 864-868). IEEE.



- [19] Deshpande, D., Jain, M., Jajoo, A., Kadam, D., Kadam, H., & Kashyap, A. (2023, October). Next-Gen Security: YOLOv8 for Real-Time Weapon Detection. In 2023 7th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC) (pp. 1055-1060). IEEE.
- [20] Shareef, A. A. A., Yannawar, P. L., Abdul-Qawy, A. S. H., Al-Nabhi, H., & Bankar, R. B. (2023, August). Deep Learning Based Model for Fire and Gun Detection. In First International Conference on Advances in Computer Vision and Artificial Intelligence Technologies (ACVAIT 2022) (pp. 422-430). Atlantis Press.



Detección de armas mediante visión artificial utilizando técnicas de aumentación de datos

Gilbert F Pérez-García¹; Alexis de J Flores García¹; Elías N Escobar-Gómez¹; Jorge A Sarmiento-Torres¹; María C Salgado-Gutiérrez¹

¹ Tecnológico Nacional de México/l. T. de Tuxtla Gutiérrez, Tuxtla Gutiérrez, Chiapas, México. Autor responsable: gilbert.pg@tuxtla.tecnm.mx

Resumen

En este estudio, se presenta el desarrollo de un sistema de detección de armas basado en visión artificial, diseñado para fortalecer la seguridad en entornos críticos, como aeropuertos, escuelas y áreas públicas. La metodología propuesta se fundamenta en el procesamiento de imágenes y el aprendizaje profundo, orientado a la identificación de armas de fuego. Para este propósito, se implementa el modelo de detección de objetos YOLO, específicamente la versión 8. El proceso de entrenamiento se lleva a cabo empleando un conjunto de datos de dominio público modificado mediante técnicas de aumentación de datos. La ejecución del modelo se realiza en un ordenador de computadora logrando con esto, una detección en tiempo real. Cuando se detecta una posible arma de fuego, el sistema genera una alarma discreta e instantánea, alertando a las autoridades responsables, lo que acelera los tiempos de respuesta y simultáneamente registra el incidente. Es importante destacar que la ética y la privacidad son consideraciones prioritarias en este proyecto, asegurando que el sistema se centre exclusivamente en la identificación de armas de fuego, sin invadir la privacidad de las personas. En resumen, este proyecto representa las bases para el desarrollo de sistemas orientados a la aplicación responsable de la inteligencia artificial para reforzar la seguridad pública, proporcionando una capa adicional de protección respaldada por precisión, rapidez y consideraciones éticas.

Palabras clave: Detección de armas, YOLOv8, visión artificial, Aprendizaje profundo, redes neuronales convolucionales.

Introducción

La visión artificial es una tecnología revolucionaria que ha transformado la forma en que interactuamos con el mundo que nos rodea. Su capacidad para procesar imágenes y extraer información valiosa de ellas ha encontrado aplicaciones en una amplia gama de campos, desde la medicina hasta la industria automotriz. En particular, la visión artificial ha incursionado en el tema de seguridad [1] como una herramienta de apoyo para el cumplimiento de la ley, desarrollando técnicas de detección para implementación en sistemas integrados. En la actualidad, la detección de armas es una de las preocupaciones más apremiantes en la población, por lo que, contar con sistemas eficientes y confiables para llevar a cabo la detección de armas peligrosas es esencial. Los sistemas tradicionales de detección de armas a menudo dependen de la revisión manual de imágenes o la implementación de escáneres de rayos X, lo que ralentiza el proceso, aumentando la posibilidad de errores y, en muchos casos, infringe la privacidad de las personas. En este sentido, la detección de armas mediante visión artificial ofrece ventajas significativas. Su enfoque no implica la revisión física, lo que preserva la privacidad de las personas. Esto reduce la resistencia a la implementación de



estos sistemas, permitiendo una revisión más transparente y sin causar molestias a quienes están siendo evaluados.

Por otro lado, la visión artificial tiene la capacidad de analizar imágenes de video en tiempo real y detectar armas de manera automática y precisa. Esto se debe a su capacidad para procesar grandes cantidades de datos en fracciones de segundo, lo que permite a estos sistemas identificar posibles amenazas de manera más rápida. Lo que destaca especialmente es su capacidad para procesar información en tiempo real y enviar alertas a las autoridades casi al instante, lo que representa una ventaja clave de la visión artificial en la detección de armas. Los sistemas tradicionales de detección de armas a menudo generan falsas alarmas o dependen del juicio de los operadores, lo que resulta en falsos positivos y molestias para las personas inocentes. En este sentido, la visión artificial mejora la eficiencia y reduce las interrupciones no deseadas en el proceso de detección de armas. La visión artificial se caracteriza por su alta precisión, y a través de su proceso de entrenamiento, es posible ajustar varios parámetros configurables para adaptar el modelo a las necesidades específicas de una aplicación o del entorno en el que se utilizará el sistema. Esto conlleva a una reducción significativa de los falsos positivos, lo que a su vez resulta en una mejora en la eficacia y una disminución de las interrupciones no deseadas.

En esta investigación, se describe el desarrollo de un sistema inteligente de detección de armas basado en visión artificial y aprendizaje profundo, diseñado para la identificación de armas de fuego en entornos cerrados con iluminación controlada. El propósito principal de este sistema es fortalecer la seguridad en entornos críticos y restringidos, ofreciendo una capa adicional de protección respaldada por la precisión y la velocidad. La implementación se ha realizado utilizando un algoritmo de detección de objetos conocido como YOLO en su versión más reciente, YOLOv8 [2]. Este algoritmo se ha destacado por su capacidad para realizar identificaciones precisas en tiempo real, lo que lo convierte en una herramienta valiosa para la detección de armas. El proceso de entrenamiento se ha llevado a cabo utilizando un conjunto de datos público que se encuentra alojado en los servidores de Roboflow y ha sido compartido por la Universidad de Granada.

Las principales contribuciones de esta investigación son las siguientes:

- Se ha fortalecido el modelo entrenado mediante técnicas de aumentación de datos, lo que ha resultado en un conjunto de datos modificado con 8913 imágenes.
- El desarrollo del modelo entrenado se ha presentado con una precisión de 0.97239, una sensibilidad de 0.96477 y un equilibrio del sistema medido a través de la métrica mAP de 0.98767 con un factor de confianza de 0.5 y 0.86446 con un factor de confianza de 0.95.

El uso de técnicas de aumento de datos en el ámbito de la visión artificial es fundamental para fortalecer los conjuntos de datos utilizados en el entrenamiento de modelos de predicción. Estas técnicas ofrecen diversas formas de enriquecer el conjunto de datos, lo que resulta en un aprendizaje más efectivo. Por ejemplo, en algunos estudios [3,4], se utiliza la minería de datos para generar muestras relacionadas con actividades delictivas. Esto se logra mediante algoritmos que



buscan patrones específicos en grandes cantidades de datos. Además, para adaptar los modelos de detección a diferentes contextos, como la elección de detectores de objetos específicos, se utilizan conjuntos de datos variados. Por ejemplo, en [5], los autores utilizan la red Inception v3 como base y fortalecen su conjunto de datos a través de técnicas de aumento de datos. Lo que es interesante es que afirman que su metodología de aumento es dinámica y no se basa en replicar el mismo archivo una y otra vez. Por otro lado, algunos investigadores optan por la generación de datos sintéticos en

lugar de simplemente aumentar los datos existentes, como se menciona en [6]. Esta estrategia proporciona información diversa que enriquece aún más el aprendizaje de los modelos de detección.

En resumen, el uso de técnicas para ampliar los datos desempeña un papel muy importante al ofrecer diversas perspectivas de las imágenes originales presentes en un conjunto de datos. Esta combinación de aumento de datos y visión artificial ha traído una revolución en la detección de armas, proporcionando muchas ventajas. Su capacidad para procesar grandes cantidades de información visual en tiempo real, adaptarse a diferentes entornos y funcionar en diversas condiciones de iluminación la convierte en una herramienta esencial para la seguridad y la aplicación de la ley. Además, su capacidad para integrarse con otros sistemas de seguridad, reducir las alarmas falsas y respetar la privacidad de las personas la convierte en una opción factible para aplicaciones de detección de armas.

Materiales y métodos

En esta sección, se detallan los materiales y la metodología utilizados en este estudio. Nuestro objetivo principal es desarrollar un sistema físico capaz de detectar armas de fuego en entornos cerrados, ya sea a través de imágenes, videos o en tiempo real mediante cámaras de videovigilancia. Para lograr la identificación de las armas, empleamos un modelo previamente entrenado utilizando el conjunto de datos MS COCO (que significa Microsoft Common Objects in Context), que contiene alrededor de 91 tipos de objetos diferentes con un total de 2.5 millones de instancias etiquetadas en 328,000 imágenes. La ventaja de utilizar un modelo preentrenado radica en la capacidad de aprovechar el conocimiento previamente adquirido por la red neuronal.

Además, durante el proceso, utilizamos el algoritmo YOLO (You Only Look Once) (ver Figura 11) para analizar la escena. Este algoritmo se destaca por su capacidad para emplear capas neuronales convolucionales al final de la red, evitando la necesidad de transformarlas en una red convencional. Gracias a esta característica, el algoritmo es capaz de analizar la escena a una velocidad notable de 60 fotogramas por segundo (FPS), incluso en sistemas informáticos convencionales (CPUs).






Figura 11. Comparativa de YOLOv8 con otros modelos de YOLO

Para la adquisición de imágenes, se ha empleado una cámara de video IR wyze cam v3, que dispone de una resolución de 1080 píxeles, características de visión nocturna, con un campo de

visión de 130°. Para las imágenes se capturan a una resolución de 640 píxeles con una velocidad de grabación de 30 fotogramas por segundo.

Conjunto de datos

Para llevar a cabo la transferencia de conocimiento en la identificación de armas de fuego, utilizamos un conjunto de datos de acceso público que se encuentra alojado en el servidor de Roboflow. Este conjunto de datos consta de 2986 imágenes y 3448 etiquetas que se refieren a una única categoría de anotación: pistolas. Las imágenes muestran una variedad de contextos, como personas sosteniendo pistolas, representaciones de dibujos animados y representaciones de alta calidad en entornos de estudio relacionados con armas de fuego. Este conjunto de datos se originó en un proyecto de la Universidad de Granada y fue sometido a una depuración que incluyó la eliminación de duplicados antes de ser nuevamente alojado en Roboflow por un colaborador.

Preprocesamiento del conjunto de datos

El conjunto de datos proporcionado por Roboflow consta de 2986 imágenes, cada una con una resolución de 415 píxeles. Utilizar técnicas de aumento de datos es esencial para mejorar el entrenamiento del modelo. Estas técnicas generan nuevas versiones de las imágenes, lo que amplía la variedad de patrones presentes en ellas. Esto, a su vez, permite que la red neuronal pueda aprender de manera más efectiva y generalizar mejor. La Figura 2 muestra cómo se ven las imágenes después de aplicar estas transformaciones.

Para llevar a cabo este proceso, se realizaron cuatro tipos diferentes de transformaciones en las imágenes del conjunto de datos.

Donde:

x : denota el eje horizontal

y : denota el eje vertical

θ : denota el ángulo de rotación

La primera transformación es la reflexión horizontal (Ec. 1), que implica una inversión de la imagen alrededor de un eje vertical imaginario, generando una imagen reflejada horizontalmente.



Figura 12. Ejemplo de imagen del conjunto de datos. a) Imagen original, b) Imagen con inversión horizontal, c) Imagen con inversión vertical, d) Imagen con inversión horizontal y vertical.

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (\text{Ec. 1})$$

La segunda transformación es la reflexión vertical (Ec. 2), en la que utilizamos un eje horizontal imaginario y aplicamos una transformación geométrica que invierte la imagen alrededor de este eje, generando una imagen reflejada verticalmente.

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (\text{Ec. 2})$$

La tercera transformación es una reflexión combinada o reflexión en el origen (Ec. 3), en la que aplicamos la transformación geométrica para invertir la imagen alrededor de ambos ejes imaginarios, es decir, el eje horizontal y el eje vertical. Esto crea una imagen que está reflejada tanto horizontal como verticalmente de manera simultánea.



$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} -1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (\text{Ec. 3})$$

En la cuarta transformación se realiza la rotación de la imagen sobre sus coordenadas centrales (Ec. 4).

$$I(\theta) = \begin{bmatrix} \cos \theta & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \quad (4)$$

La combinación de estas transformaciones aumentó significativamente el tamaño del conjunto de datos, expandiéndolo hasta tres veces su tamaño original, lo que resultó en un total de 8958 imágenes. La inclusión de datos adicionales en el proceso de entrenamiento contribuyó a evitar el sobreajuste que puede ocurrir cuando se entrena un modelo con una cantidad limitada de datos. De estas imágenes adicionales, el 80 %, es decir, 7166 imágenes, se utilizaron como datos de entrenamiento para el algoritmo de detección, mientras que el 20 % restante, es decir, 1792 imágenes, se reservaron como datos de validación.

Entrenamiento

En el proceso de entrenamiento, se establecieron varios parámetros cruciales. Se fijaron 100 épocas de entrenamiento (epochs = 100), se definió un tamaño de lote que especifica cuántas imágenes se procesan simultáneamente (batch = 10), y se determinaron las dimensiones de reescalamiento de las imágenes (image_size = 640). El entrenamiento se llevó a cabo en Google Colab, aprovechando el GPU de entrenamiento y utilizando Ultralytics YOLOv8.0.20. Se configuró un entorno con Python-3.10.12, torch-2.1.0+cu118 y CUDA:0 (Tesla T4, 15102MiB). El sistema de cómputo estaba equipado con 2 CPU con 12.7 GB de RAM y disponía de un espacio en disco de 27.1/78.2 GB.

Resultados y discusión.

En este estudio, se ha desarrollado un modelo de detección de armas basado en visión artificial. A continuación, se exponen los resultados obtenidos después de 100 épocas de entrenamiento y se presentan los resultados de la validación del sistema mediante diferentes escenarios de prueba.

Modelo Entrenado

El sistema fue entrenado utilizando un conjunto de datos previamente procesado mediante técnicas de aumento de datos, generando un conjunto de 8958 imágenes en total. Para evaluar el rendimiento del modelo resultante, se presentan en la Tabla 1 las métricas empleadas en su evaluación.

Una métrica ampliamente reconocida para evaluar la calidad de las predicciones en modelos de detección de objetos es la puntuación media de precisión (mAP). Los resultados del entrenamiento presentan dos variantes de esta métrica: la primera, que considera un factor de confianza igual o



superior a 0.5 (mAP_50), alcanza un valor de 0.98767, mientras que la segunda, aplicada con un factor de confianza igual o superior a 0.95 (mAP_95), muestra un valor de 0.86446.

Tabla 1. Métricas resultantes para la evaluación del modelo re-entrenado

Métrica	Valor
Factor de confianza	0.478
Factor F1	0.97
Precisión	0.97239
Sensibilidad	0.96477
mAP @ 0.5	0.98767
mAP @ 0.95	0.86446

Cada predicción se ajusta utilizando un umbral de operación, conocido como el factor de confianza. El éxito en la predicción de resultados positivos está estrechamente relacionado con la elección de este umbral. La métrica F1 se emplea para determinar este valor, ya que combina tanto la precisión como la sensibilidad del sistema en un solo indicador, proporcionando así una evaluación completa y equilibrada de su desempeño. Aunque esta métrica se utiliza principalmente en situaciones de desequilibrio en los datos, suele recomendarse como punto de partida para establecer el nivel de detección en la mayoría de los procesos de entrenamiento.

En el contexto de nuestro estudio, alcanzamos un valor de F1 de 0.97 al utilizar un factor de confianza de 0.478. Este valor representa el punto de equilibrio óptimo, garantizando la máxima cantidad de predicciones positivas con precisión sin sacrificar la sensibilidad del sistema (consulte la Fig. 3).




Figura 13. Curva característica de la métrica F1



En la Fig. 4 se muestran las curvas características de precisión y sensibilidad, dos métricas fundamentales que se complementan mutuamente. La precisión evalúa la proporción de predicciones correctas (verdaderos positivos) en relación con la suma de predicciones correctas y predicciones incorrectas (falsos positivos). Mientras que, la sensibilidad, también conocida como Recall, se enfoca en la identificación de los falsos negativos en lugar de los falsos positivos. Estas curvas permiten un análisis independiente de ambas métricas y ofrecen una comprensión más completa del rendimiento del sistema.

En la Fig. 4-b, se aprecia que a medida que aumentamos el nivel de confianza, la sensibilidad del modelo disminuye. Aunque esta disminución conlleva a una mayor precisión del sistema, también implica que el modelo se vuelve más cauteloso y menos capaz de realizar predicciones en situaciones inciertas. Esto se traduce en que el modelo se vuelve más estricto, ignorando predicciones que no cumplen con un alto estándar de confianza, tal como se ilustra en la Fig. 4-a.

De acuerdo con la métrica F1, se eligió un factor de confianza de 0.478. Al observar este umbral en las gráficas de precisión (Fig. 4-a) y sensibilidad (Fig. 4-b), se nota que, en ambos casos, tanto la precisión como la sensibilidad coinciden, logrando un equilibrio que se considera una probabilidad aceptable. Por lo tanto, este umbral puede considerarse óptimo. Sin embargo, es importante destacar que, según el contexto de implementación, este umbral puede ser ajustado para adaptarse a las condiciones específicas del entorno en el que se realizará la detección.

Validación

En esta sección, se procedió a evaluar el rendimiento del modelo propuesto, el cual ha sido implementado en la plataforma Python. El conjunto de datos utilizado previamente fue sometido a técnicas de aumento de datos como parte del proceso. En la Fig. 5, se presentan ejemplos de imágenes de entrada junto con las detecciones correspondientes. Estas imágenes fueron adquiridas de fuentes en línea y representan situaciones delictivas reales. A pesar de que el modelo fue originalmente concebido para operar en entornos cerrados como bancos, escuelas y empresas, donde la iluminación tiende a ser uniforme, las variaciones en la intensidad de la luz en las escenas de la Fig. 5 resaltan la robustez del modelo. Esta robustez se logró gracias a la selección del conjunto de datos, al preprocesamiento de imágenes y a la configuración de los parámetros durante el proceso de entrenamiento.

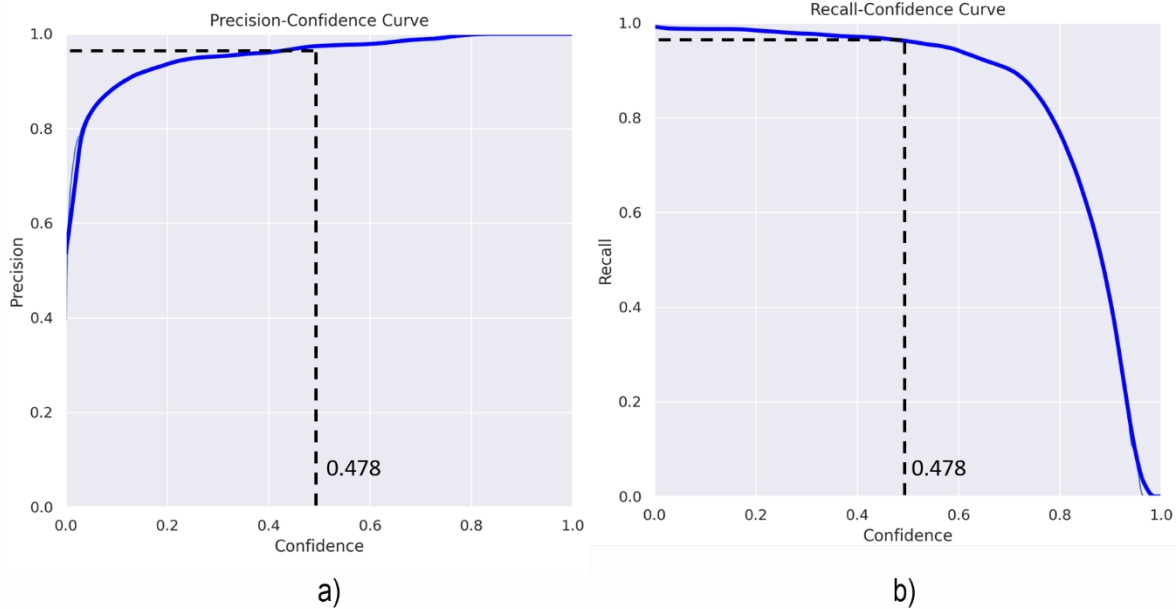




Figura 14. Curva características de a) Precisión b) Sensibilidad

Conclusiones.

En este estudio, se planteó la creación de un modelo de visión artificial diseñado para identificar armas de fuego en situaciones cotidianas. Para lograr esto, se utilizó un conjunto de datos que se sometió a un proceso de mejora mediante técnicas de procesamiento de imágenes, incluyendo cambios horizontales, verticales y con respecto al origen. El modelo se entrenó utilizando aprendizaje profundo con este conjunto de datos mejorado, con un total de 8958 imágenes. Las métricas clave que se utilizaron para evaluar el rendimiento del modelo incluyen un factor de confianza de 0.478 y un factor F1 de 0.97. Estos valores destacan la capacidad del modelo para equilibrar eficazmente la precisión de sus predicciones y su sensibilidad. Además, las métricas de puntuación media de precisión (mAP) respaldan sólidamente la eficacia del modelo, lo que confirma su rendimiento. La flexibilidad para ajustar el factor de confianza según las condiciones específicas del entorno de detección subraya la versatilidad del sistema en diferentes situaciones prácticas.

En términos de futuras investigaciones, este estudio establece una base sólida para explorar más a fondo la detección de objetos. Se abre la puerta a la adaptación del sistema a aplicaciones específicas y al desarrollo de prototipos en tiempo real en entornos cambiantes. Esta evolución tiene el potencial de hacer contribuciones valiosas en términos de seguridad.



a)

b)

Figura 15. Escenas delictivas a) Entrada de la imagen b) Salida de la imagen con caja de predicción



Referencias bibliográficas

- [1] Oñate Miranda, F. P. (2020). *Diseño y construcción de nodos inteligentes para detección de armas dentro de una red de video-vigilancia utilizando visión artificial* (Bachelor's thesis, Escuela Superior Politécnica de Chimborazo).
- [2] Terven, J., & Cordova-Esparza, D. (2023). A comprehensive review of YOLO: From YOLOv1 to YOLOv8 and beyond. *arXiv preprint arXiv:2304.00501*.
- [3] Valenga, F., Fernández, E., Merlino, H., Rodríguez, D., Procopio, C., Britos, P., & García-Martínez, R. (2008). Minería de Datos Aplicada a la Detección de Patrones Delictivos en Argentina. In *JISIC* (pp. 31-40).
- [4] Perversi, I., Valenga, F., Fernández, E., Britos, P. V., & García Martínez, R. (2007). Identificación y detección de patrones delictivos basada en minería de datos. In *IX Workshop de Investigadores en Ciencias de la Computación*.
- [5] Sánchez, J., & Campos, M. A. (2021). Red neuronal artificial para detección de armas de fuego y armas blancas en video vigilancia. *Revista de Iniciación Científica*, 7(2), 83-88.
- [6] Vallez, N., Velasco Mata, A., Cotorro, J. J., & Deniz, O. (2019). ¿Es posible entrenar modelos de aprendizaje profundo con datos sintéticos? In *XL Jornadas de Automática* (pp. 859-865). Universidade da Coruña, Servizo de Publicacións.



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO



REVISTA **DIGITAL**

TEC TUXTLA

Ciencia y Tecnología con Sentido Humano



*Revista de Divulgación Científica
del Instituto Tecnológico de
Tuxtla Gutiérrez*

No. 2 Publicación Semestral
Semestre **Agosto - Diciembre**