

EDUCACIÓN

# Investigación educativa: enfoques innovadores multidisciplinarios

Coordinadoras

Tania Morales Reynoso

Clementina Jiménez Garcés

Brenda Mendoza González





# Investigación educativa: enfoques innovadores multidisciplinares

Tania Morales Reynoso  
Clementina Jiménez Garcés  
Brenda Mendoza González

Coordinadoras



Red de Cuerpos Académicos en Investigación Educativa de la UAEM **RedCA**



CONACYT  
Registro Nacional de Instituciones  
y Empresas Científicas y Tecnológicas  
Registro: 1900555

## **Investigación educativa: enfoques innovadores multidisciplinares**

© Tania Morales Reynoso  
© Clementina Jiménez Garcés  
© Brenda Mendoza González

### **Dirección del proyecto**

Eduardo Licea Sánchez  
Esther Castillo Aguilar

### **Formación de interiores**

Vanesa Alejandra Vázquez Fuentes

### **Corrección de estilo**

Dámaris Vera Zamora

### **Preprensa**

Víctor Hugo Flores Hernández

1a. edición

© 2022 Fernando de Haro y Omar Fuentes

ISBN 978-607-437-593-0

D.R. © CLAVE Editorial

Paseo de Tamarindos 400 B, *suite* 109.

Col. Bosques de las Lomas, Ciudad de México, México. C.P. 05120

Tel. 52 (55) 5258 0279/80/81

ame@ameditores.mx

coediciones@ameditores.mx

www.ameditores.com

Las opiniones y puntos de vista expresados en la presente obra, son responsabilidad única y exclusiva de su autor y no necesariamente representan las posiciones u opiniones de la editorial, y las de sus integrantes.

Ninguna parte de este libro puede ser reproducida, archivada o transmitida en forma alguna o mediante algún sistema, ya sea electrónico, mecánico o de fotorreproducción, sin la previa autorización de los editores.

El libro fue dictaminado positivamente por pares académicos mediante el sistema doble ciego para su publicación y fue sometido a un proceso de identificación de coincidencias mediante el Software iThenticate.

Elaborado en México.





# Contenido

<b>Capítulo 1. La competencia de liderazgo como elemento de la formación integral del médico</b>	11
<i>Virgilio Eduardo Trujillo Condes, Patricia Denissy Bocanegra Lozano, Tania Marcela Domínguez del Pino, Patricia Vieyra Reyes, Clementina Jiménez Garcés</i>	
<b>Capítulo 2. Gamificación como herramienta integradora para el aprendizaje del inglés en alumnos de pregrado de Medicina</b>	27
<i>Virgilio Eduardo Trujillo Condes, Patricia Vieyra Reyes, Clementina Jiménez Garcés</i>	
<b>Capítulo 3. Competencia de egresados pasantes de Cirujano Dentista de la Universidad Autónoma del Estado de México</b>	43
<i>María de la Luz Sánchez Medina, Jorge Marcos Medina Sánchez, María de los Ángeles Ocampo García, Rosa María Bernal Osorio</i>	
<b>Capítulo 4. Inteligencia emocional, bienestar psicológico y aprovechamiento escolar, en estudiantes de Psicología</b>	59
<i>José Luis Gama Vilchis, Claudia A. Sánchez Calderón, Irma Isabel Ortiz Valdés, Horacio Roque Maldonado</i>	
<b>Capítulo 5. La psicomotricidad como medio para facilitar la expresión emocional en el niño preescolar</b>	83
<i>Beatriz Cuéllar Palapa, Carolina Islas Pascual, Maricruz Rojas García, Raquel Valerio Tapia</i>	
<b>Capítulo 6. El sentido de la contemplación de la violencia en la red entre los jóvenes estudiantes del bachillerato. Caso: un plantel de nivel medio superior del Estado de México</b>	99
<i>Tania Morales Reynoso, Brenda Mendoza González, Aristeo Santos López</i>	

<b>Capítulo 7. <i>Bullying</i>, ¿es posible detectarlo a partir de tecnología usada en robots?</b>	117
<i>Carlos Alberto Martínez-Miwa, Mario Castelán, Brenda Mendoza González</i>	
<b>Capítulo 8. La psicopedagogía de las emociones para favorecer la convivencia escolar pacífica en la educación básica</b>	133
<i>Karla Vanelly López Arriaga, María Asunción Ramírez Ramos, Filiberto Rivera Tecorral, María de Jesús Pelcastre Ledesma</i>	
<b>Capítulo 9. Las habilidades socioemocionales y el manejo de conflictos escolares en alumnos de nivel secundaria</b>	151
<i>María de los Ángeles Alarcón Colín</i>	
<b>Capítulo 10. La alteridad pedagógica, una alternativa para favorecer la convivencia pacífica en el aula de educación primaria</b>	163
<i>María Cristina Esquivel Rodríguez, Filiberto Rivera Tecorral, Fausta Toro Aparicio</i>	
<b>Capítulo 11. Fortalecimiento de hábitos de alimentación saludables en alumnos de educación primaria</b>	173
<i>Margarita Martínez Paúl</i>	
<b>Acerca de los autores</b>	185







## Capítulo 7

# *Bullying*, ¿es posible detectarlo a partir de tecnología usada en robots?

*Carlos A. Martínez-Miwa<sup>1</sup>, Mario Castelán<sup>1</sup>, Brenda Mendoza González<sup>2</sup>*

### Resumen

En investigación psicológica, particularmente en entornos educativos, se hace necesario contar con tecnología que permita diagnosticar, detectar y prevenir episodios de violencia escolar y *bullying*. La riqueza de la investigación se logra al integrar equipos multidisciplinares que permitan incidir en un fenómeno social a partir de diversas especialidades, es por ello que a partir de estudios en el área de ingeniería se ofrece este trabajo de investigación que pretende usar la ingeniería para aplicarla al estudio del *bullying*, permitiendo así tener investigación multidisciplinaria que pueda combinar la investigación educativa con las ciencias exactas.

En este trabajo se propone evaluar uno de los algoritmos para detección de objetos más reconocidos actualmente en la literatura, YOLOv3, dando especial enfoque en la identificación de personas en ambientes escolares. El trabajo es un reto no solo para la psicología en escenarios naturales como es el aula escolar, sino también para la ingeniería, ya que así como las conductas disruptivas, agresivas o la negativa a seguir instrucciones por algunos alumnos han sido una constante en las aulas en las que existe *bullying*, también es un reto para la ingeniería ya que este tipo de comportamientos han sido difíciles de identificar a través de la inteligencia artificial (YOLOv3), ya que los resultados obtenidos en este trabajo hacen ver que al aumentar el tamaño de la imagen de entrada y reducir la cuadrícula de búsqueda, se consigue incrementar el porcentaje de éxito en las detecciones del alumnado, así como su precisión (al identificar posturas o algún tipo de movimiento específico), por lo que el estudio de la violencia escolar y el *bullying* se hace posible a través del uso de las ciencias exactas en combinación de las ciencias sociales.

## Introducción

El análisis experimental de la conducta estudia comportamientos socialmente relevantes a través del análisis de interacciones sociales (Santoyo, 2013). Esta perspectiva permite analizar cómo el comportamiento de un miembro de una diada afecta la conducta del otro, identificando las variables ecológicas que también influyen en el comportamiento, tales como: el lugar, la disposición de los estímulos y la jerarquía de cada uno de los miembros de la diada, de tal manera que existe un intercambio con el medio social (Santoyo, 2009).

La agresión es un tipo de comportamiento con relevancia social, cuya descripción y análisis ha permitido describir los factores proximales que la regulan en niños (reciprocidad, vínculos sociales, tiempo dedicado al comportamiento académico). Los niños que exhiben mayor comportamiento agresivo son los que muestran más la reciprocidad coercitiva; es decir, intercambios agresivos con sus pares como reacción a un evento que perciben agresivo, señalándose que, mientras mayor comportamiento agresivo se exhibe, menor es el tiempo que se invierte para desarrollar trabajo escolar (Santoyo y Mendoza, 2018).

El estudio de los intercambios sociales entre niños ha permitido describir subtipos del comportamiento agresivo ocurridos en escenarios escolares como el denominado *bullying* o acoso escolar (su traducción en castellano, Mendoza, 2014), descrito desde hace varias décadas. El comportamiento de *bullying* puede ser explicado a través de la teoría de la coerción, que se ha estudiado y descrito a través de la observación sistemática del comportamiento agresivo de niños (de edad escolar) en la interacción con sus padres y también con sus iguales.

El comportamiento agresivo se describe como un proceso de reforzamiento mutuo, a través del cual la diada (padre e hijo o niño-niño) que participa en los intercambios sociales agresivos exhibe escaladas que son usadas para controlar el comportamiento del otro, por lo que el niño, desde edades tempranas, aprende a manipular el comportamiento de padres o iguales (Patterson, 1982).

La teoría de la coerción explica cómo conductas no agresivas (por ejemplo, desobediencia o berrinches) conforman la base de la manifestación y mantenimiento de conductas agresivas y antisociales. Generalmente, el ciclo de estos intercambios coercitivos comienza cuando el niño se rehúsa a seguir alguna instrucción del adulto, por lo que se inicia el escalamiento o incremento de agresión durante la interacción del niño y el adulto. El niño generaliza este comportamiento a otros escenarios como el escolar, y lo aprende a usar con pares y maestros, por lo que el patrón conductual es estable a lo largo de su desarrollo en diferentes escenarios (Granic y Patterson, 2006). Esta teoría ha permitido incidir con éxito en modelos de intervención conductual dirigida a los agentes de cambio (padres y profesores)

enseñándoles a evitar intercambios coercitivos y su escalamiento (Mendoza, 2014; Mendoza, 2017; Cuenca y Mendoza, 2017; Mendoza y Pedroza, 2015).

Los intercambios coercitivos entre padres e hijos se extienden a otros contextos como el escolar. Especialmente, el niño aprende a emitir conductas coercitivas en la relación que establece con sus profesores y compañeros de clase (Mendoza, Pedroza y Martínez, 2014), por lo que conviene estudiar en el contexto escolar, además del *bullying*, la interacción entre profesores y alumnos, así como otros elementos que conforman el clima escolar.

### **Clima escolar y *bullying***

El clima escolar se conforma por diversos factores, como la aplicación del código de conducta, la relación profesor-alumno, valores, las prácticas de enseñanza-aprendizaje, la estructura organizacional, la gestión en la institución e intervención del profesorado (AlMakadma y Ramisetty-Mikler, 2015; Beaudoin y Roberge, 2015), así como la participación de los padres (monitoreo parental en actividades escolares y comunicación con profesorado) y el cuidado del ambiente físico del plantel escolar (AlMakadma y Ramisetty, 2015; Thapa, Cohen, Higgins, & Guffey, 2012).

Se ha identificado que algunos factores que impactan en el clima escolar son el aislamiento y la victimización del alumnado (Povedano, Cava, Monreal, Varela, y Musitu, 2015). Asimismo, el estrés que los episodios de violencia generan en el profesorado causa un clima negativo en el aula, ya que la violencia le impide impartir clase, afectando el proceso enseñanza-aprendizaje (Ozkilic, & Kartal, 2012).

Otros factores que afectan el clima de una escuela son las salidas constantes del alumnado (para evitar clase), la percepción que tienen con respecto del código escolar, especialmente cuando perciben que no se opera (por ejemplo, encontrar al alumnado rompiendo alguna regla, y no establecer consecuencias), y la exclusión que sienten de sus compañeros y del profesorado (Giovazoliasa, Kourkoutasb, Mitsopouloua y Georgiadib 2010).

Por otra parte, se ha constatado que se propicia un clima escolar positivo cuando el alumnado se siente bien en la escuela, disfruta lo que hace en ella, percibe un entorno agradable de aprendizaje, y se siente valorado y aceptado, dentro de un ambiente en el que el profesorado brinda apoyo, confianza y respeto (Beaudoin y Roberge, 2015). El clima escolar positivo configura un espacio de interacción social en el que el profesorado favorece la vinculación positiva entre los alumnos, además de mostrar interés y un trato justo hacia ellos. De esta manera, se consigue mejorar el proceso de aprendizaje, así como la calidad entre las interacciones del alumnado, previniendo la violencia escolar y disminuyendo la victimización en el aula (Giovazoliasa et al., 2010; Hendrickxa, Mainharda, Boor-Klipb, Cillessenb & Brekelmans, 2016;

Mendoza, Delgado y García, 2020). En el desarrollo del clima escolar positivo, el principal agente para motivar al alumnado a desarrollar su trabajo académico es el profesorado (Mendoza, ). Este, de igual manera, ayuda a los estudiantes a percibir como positivo el tiempo que invierten para desarrollar sus tareas, facilitando la percepción de un ambiente positivo en el contexto escolar (Espinoza, 2006) demostrándose que, mientras mayor es el apoyo y soporte que el profesor brinda a sus alumnos, menor será la transgresión a normas escolares afectando el clima escolar (Povedano *et al.*, 2015).

Uno de los problemas a los que se enfrenta la investigación de la violencia y acoso escolar (*bullying*) es no contar con tecnología que permita tener observaciones precisas del comportamiento, lo que sin duda permitiría tener mayor información de la morfología del comportamiento violento. Así, pues, el trabajo multidisciplinario, en especial con áreas de ciencias exactas, ayudará a disminuir significativamente esta problemática que incide en el diagnóstico, prevención y detección de dichas conductas.

Por lo anteriormente descrito, el objetivo de la presente investigación consiste, entonces, en determinar las limitaciones de YOLO (Redmon, Divvala, Girshick y Farhadi, 2016) para la detección de estudiantes en entornos escolares, especialmente en comportamientos como conducta disruptiva, violencia escolar y *bullying*, dando paso a potenciales mejoras en las áreas de psicología e ingeniería.

### **Planteamiento del problema: *bullying*, ingeniería y uso de inteligencia artificial aplicada al ambiente escolar**

Debido a la constante necesidad de diseñar e incorporar sistemas de monitoreo y vigilancia visual en distintos ambientes propensos a problemas de seguridad y violencia, tales como aeropuertos, bancos o escuelas, la detección precisa de personas es un área de investigación importante dentro de la inteligencia artificial, específicamente la denominada visión por computadora.

La función principal de estos sistemas es alertar a las autoridades sobre situaciones sospechosas o potencialmente peligrosas. Lamentablemente, estas tareas a menudo resultan ineficaces debido a la cantidad insuficiente de supervisores a cargo del monitoreo, o bien, a los tiempos de respuesta lentos derivados de los límites naturales de las capacidades de atención humana.

Además de las aplicaciones en seguridad, otras áreas como la psicología experimental utilizan estrategias como reuniones con maestros y niños o métodos de observación directa (Santoyo y Mendoza, 2018), con el propósito de investigar casos de violencia escolar. No obstante, este tipo de metodologías involucran ciertas desventajas: 1) consumen mucho tiempo; 2) basan su desempeño en la

observación de los investigadores a cargo, pudiendo derivar en resultados un tanto subjetivos, y 3) la presencia física de vigilantes puede llegar a influir o condicionar las actitudes de los sujetos de estudio (alumnos o profesores), obstaculizando la apreciación de su comportamiento real.

Esta problemática ha provocado que la identificación humana, basada en evidencia visual (i.e., cámaras de video), recientemente haya ganado un interés más amplio por parte de la comunidad experta en inteligencia artificial, especialmente en el área de visión por computadora (Fragkiadaki, Levine, Felsen y Malik, 2015; Gao, Liu, Sun, Wang y Liu, 2016; Idrees, Shah y Surette, 2018; Mohamed, 2015; Subetha y Chitrakala, 2017). Dentro del estado del arte existen ya enfoques que tienen como objetivo la detección de objetos a partir de bases de datos prediseñadas, como por ejemplo Microsoft COCO (Lin, Maire, Belongie, Hays, Perona, Ramanan y Zitnick, 2014). Si bien éstas contemplan una gran variedad de categorías, la clase “persona” resulta ser una de las más desafiantes.

Los seres humanos, en comparación con objetos rígidos como una mesa o una silla, estamos sujetos a deformaciones. De igual forma, los individuos se encuentran en constante movimiento, tendiendo incluso a formar multitudes. Estas condiciones pueden derivar en la presencia de condiciones altamente desafiantes, como oclusiones, traslape o mucha proximidad, provocando que para un sistema computacional sea difícil distinguir si un objeto corresponde a la categoría “persona” o no.

Dentro de entornos específicos, como por ejemplo aulas de aprendizaje, los estudiantes se encuentran comúnmente sujetos a potenciales oclusiones derivadas de sus movimientos súbitos, además de que la presencia de objetos escolares típicos, como escritorios o mochilas, puede impedir una observación completa del cuerpo y rostro de los alumnos. Asimismo, la disposición de los escritorios puede propiciar una captura de imágenes donde aparezcan alumnos con alta resolución (ceranos a la cámara), y con baja resolución (alejados de la cámara) obstaculizando la adquisición de información.

Por esta razón, se propone evaluar el desempeño de una de las metodologías de detección de objetos más reconocidas actualmente en el estado del arte de visión por computadora, YOLO (*You Only Look Once*).

La detección de objetos es una parte fundamental en el área de inteligencia artificial, específicamente en el área de visión por computadora, ya que se utiliza para identificar regiones de una imagen, que pertenecen a un objeto del mundo real. Los métodos clásicos extraen a partir de una región de interés, ROI (*Region of Interest*), características tales como patrones binarios locales, LBP (*Local Binary Patterns*) (Li, Feng, Xia, Jiang y Hadid, 2018) o los histogramas de gradientes orientados, HoG (*Histogram of Oriented Gradients*) (Dalal y Triggs, 2005). Las ROI obtenidas son posteriormente sujetas a técnicas de clasificación.

Hoy en día, diversas metodologías de aprendizaje profundo o *Deep Learning*, como las redes neuronales convolucionales, CNN (*Convolutional Neural Networks*), son empleadas para localizar y clasificar objetos dentro de una imagen o secuencia de video en tiempo casi real.

Existen dos principales categorías para estas redes:

1. Las CNN basadas en detección de regiones, R-CNN (*Region based-Convolutional Neural Networks*), como Fast R-CNN (Girshick, 2015), Faster R-CNN (Ren, He, Girshick y Sun, 2015).
2. Las CNN basadas en regresión (SSD [Liu, Anguelov, Erhan, Szegedy, Reed, Fu y Berg, 2016] y YOLO).

La decisión de optar por el algoritmo YOLO es debido a que, en comparación con otros sistemas similares, posee una mayor velocidad de detección sin comprometer su precisión. Esto resulta sumamente importante pues, en la identificación de estudiantes en ambientes escolares que presentan un sinnúmero de movimientos, cambios de postura e interacciones constantes con otros, el tiempo de respuesta puede ser crucial.

Por tanto, la pregunta de investigación consiste en responder ¿el algoritmo YOLO tiene limitaciones para detectar estudiantes en entornos escolares, especialmente en comportamientos como conducta disruptiva, violencia escolar y *bullying*?

## Metodología

### *Objetivo general:*

Detectar con precisión a niños y docentes con el algoritmo YOLOv3 en aulas en las que se exhibe comportamiento disruptivo, desobediencia y *bullying*.

### *Objetivos Específicos:*

Fase 1. Buscar imágenes de niños, niñas y docentes en entornos académicos.

Fase 2. Identificar con precisión, a través de inteligencia artificial, (algoritmo YOLOv3) a seres humanos en un aula de clase.

### *Materiales e instrumentos*

Se usaron videos de alumnos que pertenecían a un aula identificada con comportamiento de *bullying*. En los videos aparece alumnado de educación primaria (tercer año de primaria), con rango de edad entre 8 y 10 años, inscritos en una escuela pública en Toluca, Estado de México. Se solicitó el consentimiento informado de los padres para ser videograbados, especificándose que los videos únicamente se usarían con fines de investigación.



También se usó un algoritmo que detecta objetos a través de inteligencia artificial, específicamente visión por computadora.

Se empleó el algoritmo YOLO en su tercera versión (YOLOv3, Redmon y Farhadi, 2018), que es una versión mejorada de *You Only Look Once*.

YOLOv3 tiene por objetivo detectar objetos a través de la visión por computadora y es apropiado para esta investigación, ya que permite identificar regiones de una imagen que pertenecen a un objeto del mundo real, siendo en este caso el alumnado de educación primaria.

Este algoritmo, en la actualidad, ofrece una detección de objetos a una mayor velocidad que otros algoritmos existentes. YOLO reconoce las regiones y calcula sus probabilidades de clasificación en un solo paso, de ahí su nombre.

La experimentación desarrollada fue llevada a cabo bajo un procesador doble núcleo a 2.4 GHz y una memoria RAM de 8GB. El algoritmo YOLOv3 fue ejecutado en la red Darknet53 (Redmon, 2016) implementada bajo el lenguaje de programación C, y fue preentrenado con la base de datos Microsoft COCO (Lin, Maire, Belongie, Hays, Perona, Ramanan y Zitnick, 2014).

## Procedimiento

La investigación tiene dos fases. La primera de ellas es la búsqueda de imágenes de alumnado en aulas escolares, mientras que la segunda fase consiste en el uso del algoritmo adaptándolo a las particularidades del entorno educativo. A continuación se describen cada una de ellas.

### *Fase I. Búsqueda de imágenes*

Para cumplir con el objetivo de esta fase, se utilizaron 31 imágenes de entornos escolares. Ocho de ellas fueron obtenidas a partir de una exploración en el buscador Google bajo las palabras clave salón de clases, estudiantes, *classroom students*, *students misbehavior*, *bullying*.

Adicional a la exploración en Google, se identificaron imágenes obtenidas de aulas de escuelas públicas del Estado de México, que contenían a niños, niñas y docentes que desarrollaban actividades cotidianas e inherentes a su vida escolar durante la jornada de clases, como trabajar en equipo, seguir la instrucción del profesor o desobedecer, pegar a otros compañeros de clase, levantarse de su lugar, conversar entre ellos, entre muchos otros comportamientos.

### *Fase II. Particularidades del entorno académico*

Se analizaron 31 imágenes de entornos académicos a través del algoritmo YOLOv3, el cual permite detectar personas en imágenes con precisión. Las regiones co-

rrespondientes a cada sujeto, o *bounding boxes*, fueron anotadas manualmente tomando en cuenta todas aquellas partes del cuerpo que fueran visibles. En total se generaron 456 regiones como referencia o *groundtruth*.

## Resultados

Al emplear la inteligencia artificial a través del algoritmo YOLOv3, para que se reconociera a cada uno de los alumnos del aula escolar, sin importar su posición o comportamiento, se identificó que YOLOv3 tiene dificultades para detectar al alumnado, particularmente en un aula en la que existe comportamiento disruptivo y *bullying*.

El algoritmo YOLOv3 no es capaz de identificar a niños y niñas cuando se encuentran en posiciones y posturas particulares, tales como estar recostados sobre su banca, cuando se encuentran conversando juntos, al estar físicamente muy cerca (hombro con hombro) o bien, cuando se impide la visibilidad de un alumno, ya sea por otro estudiante o por objetos encontrados en un aula escolar típica, como mochilas o escritorios. Por tal motivo, se prosiguió a comprobar si estos problemas eran ocasionados, ya sea por cuestiones de entrenamiento, o debido a la estrategia de búsqueda.

Los resultados demostraron que el algoritmo YOLOv3 sufre para detectar a la mayor parte de los estudiantes presentes en la imagen. Esto puede deberse a las múltiples oclusiones o la baja resolución de la imagen. Para precisar si las personas que no fueron detectadas se debieron a cuestiones de entrenamiento, cada uno de los parches (secciones de la imagen) correspondientes a estos alumnos fue dado como entrada al algoritmo YOLOv3; es decir, como si cada región fuese una imagen completa. En total se evaluaron 152 regiones.

Como resultado de este experimento, todos los parches fueron clasificados de manera correcta. De esta manera, es posible suponer que los inconvenientes ocurridos no son consecuencia del entrenamiento de la red.

Asimismo, la experimentación desarrollada sugiere que estos problemas son ocasionados por la estrategia de búsqueda de objetos empleada. YOLOv3 toma las imágenes de entrada originales, las somete a un redimensionamiento y genera una cuadrícula o mallado de  $S \times S$  con base en estas nuevas medidas. Para cada celda de la cuadrícula, el algoritmo predice 3 ventanas o *bounding boxes* responsables de llevar a cabo la búsqueda y detección de los objetos de interés, así como el valor de confianza para cada una de ellas. Con el objetivo de verificar la influencia del tamaño de la imagen de entrada, provocamos variaciones de  $416 \times 416$ ,  $608 \times 608$  y  $960 \times 960$  píxeles. Este procedimiento abre la posibilidad de conseguir cuadrículas cada vez más finas, permitiendo la detección de objetos más pequeños. Es importante resaltar que el tamaño de imagen de entrada no representa las dimensiones originales de las imágenes, sino


que corresponde al redimensionamiento que realiza YOLOv3, mismo que condiciona el tamaño final de la cuadrícula empleada para la detección de personas.

A medida que el tamaño de la imagen de entrada se incrementa, es posible observar que el mallado se vuelve más fino. Esto permite mejorar la detección de estudiantes difíciles de localizar en la imagen, ya sea por su lejanía, por encontrarse ocluidos por otro alumno o por su postura.

Para las 31 imágenes y un total de 456 regiones, por cada tamaño de cuadrícula se calcularon los porcentajes de éxito en el número de estudiantes detectados con respecto a la referencia o *groundtruth* anotada manualmente, considerando todas aquellas partes del cuerpo, de cada persona, que fueran visibles.

En la Figura 1 se puede apreciar que mientras las dimensiones de la imagen de entrada se incrementan de 416x416 a 608x608 y 960x960, lo hacen también los porcentajes de éxito alcanzando  $66.4046\% \pm 23.3942$ ,  $75.4265\% \pm 17.4421$  y  $83.4338\% \pm 13.8409$ , respectivamente.

Fig. 1. Porcentaje de éxito en la detección




En la Figura 1, se identifica que el eje  $x$  representa los tres tamaños de imagen de entrada empleados. El eje  $y$  hace referencia al porcentaje de éxito en las detecciones de estudiantes (456 regiones en total). Como puede apreciarse, a medida que el tamaño de la imagen de entrada se acrecienta, la cantidad de detecciones lo hace igualmente. Esto puede deberse a que, a medida que el tamaño de la imagen aumenta, la cuadrícula para la búsqueda de objetos se vuelve más fina logrando detectar una mayor cantidad de individuos.

Ahora bien, para evaluar la precisión de las detecciones en cada uno de los tamaños de la imagen de entrada, se recurrió a la intersección sobre unión o IoU (Intersection over Union):

$$IoU = \frac{Deteccion \cap GroundTruth}{Deteccion \cup GroundTruth}$$

Dicha métrica calcula el porcentaje de traslape entre la *bounding box* detectada y la correspondiente al *groundtruth*, con respecto a la suma del área de ambas regiones. En la Figura 2 es posible observar los resultados generados para las 31 imágenes variando los 3 tamaños de entrada. Resulta evidente cómo es que, a medida que la imagen de entrada se hace mayor, el valor del IoU crece igualmente:  $0.4116 \pm 0.3806$  para  $416 \times 416$ ,  $0.5214 \pm 0.3783$  para  $608 \times 608$  y  $0.5973 \pm 0.3371$  cuando las medidas son  $960 \times 960$ .

Fig. 2. Relación entre la intersección y unión de las detecciones y el *groundtruth* (IoU)



En la Figura 2 se observa que el  $x$  representa los tres tamaños de imagen de entrada empleados. Por su parte, el eje  $y$  corresponde al IoU de las *bounding boxes* detectadas y las de referencia. Puede observarse cómo es que conforme crece el tamaño de la imagen de entrada, la exactitud de las detecciones aumenta. Mientras más pequeño sea el tamaño de la imagen de entrada, la cuadrícula de búsqueda se vuelve menos detallada, generando *bounding boxes* que, si bien detectan correctamente ciertas personas, contemplan también objetos cercanos a ellas. Así, al incrementarse el tamaño de la imagen, la cuadrícula para la búsqueda de objetos se torna más fina logrando obtener *bounding boxes* cada vez más ajustadas a los objetos de interés; es decir, a las personas. Esto es de gran importancia para la investigación en psicología experimental pues, para lograr una certera determinación de indicadores de casos de violencia escolar, es necesaria una detección precisa de los alumnos.

**Conclusiones**

Los experimentos demuestran que el algoritmo YOLOv3 presenta dificultades para detectar personas en entornos escolares debido a inconvenientes, tales como oclusiones por la presencia de objetos, o bien la captura de imágenes con baja resolución

derivadas del movimiento constante de los alumnos y la disposición de los escritorios. De esta manera, se puede establecer que la detección de seres humanos (niños y niñas) en un aula escolar con comportamiento disruptivo, violento, de desobediencia y *bullying*, es un reto no sólo para la educación, sino también para la ingeniería. Esto se debe a que las particularidades del entorno áulico son tan complejas, que el algoritmo YOLOv3 no fue capaz de detectar con precisión a los niños y niñas.

Fue posible determinar, también, que la mencionada problemática no parece ser resultado del entrenamiento, pues al evaluar de manera aislada cada uno de los parches que no fueron detectados en una primera instancia, éstos fueron clasificados acertadamente.

De igual manera, se demostró que al hacer adaptaciones al algoritmo y aumentar el tamaño de la imagen de entrada con el fin de conseguir una búsqueda detallada de objetos en una cuadrícula más fina, se logró incrementar el porcentaje de éxito en las detecciones, así como la precisión de las mismas; lo anterior, gracias a la inteligencia artificial aplicada a las peculiaridades en dicha aula.

Como trabajo futuro, sería interesante estudiar a profundidad el impacto de la variación de los umbrales empleados por YOLOv3; por ejemplo, los valores de *objectness* y *non-maximum suppression*, en la detección de personas.

De igual forma, es importante desarrollar estrategias que permitan combatir y resolver el problema de detección de diversos sujetos en una sola *bounding box*, ocasionado por el traslape y las oclusiones entre individuos, propios de entornos altamente desafiantes como lo es un salón de clases. Por último, se buscaría atacar el inconveniente de la identificación de “personas” de gran tamaño (improbables de encontrar en un aula de aprendizaje), además de la sensibilidad del mallado, expuesta en el recientemente publicado YOLOv4 (Bochkovskiy, Wang y Liao, 2020).

Este trabajo fue un gran reto para la línea de investigación de inteligencia artificial, al conocer que los algoritmos empleados presentan serias problemáticas para identificar personas en un salón de clases que presenta comportamiento de *bullying*. Sin embargo, también fue un reto para la psicología aplicada en ambientes educativos, ya que el aula participante tuvo que tener una intervención especializada (Mendoza, 2014; Mendoza, 2017) para decrementar las conductas violentas que cotidianamente se exhibían. Por tanto, resulta evidente que el reto para la ciencia en el área social también lo es para las ciencias exactas.

Finalmente, es pertinente mencionar que este trabajo busca sentar las bases para el desarrollo de metodologías orientadas a apoyar protocolos de investigación en psicología experimental, especialmente en entornos académicos; por ejemplo, estudio del *bullying*, específicamente su uso será para diagnóstico. Hasta ahora no se ha publicado ninguna investigación que persiga los mismos objetivos, por lo que es una propuesta novedosa para la detección de *bullying*.

Al tener una detección precisa de los estudiantes será posible buscar indicadores, tales como emociones faciales o la orientación de la cabeza, que puedan apoyar las observaciones de los investigadores, relacionadas a estados de ánimo y atención de los alumnos, orientadas al trabajo de diagnóstico con el objetivo de decrementar fallas humanas y dirigidos a tener un diagnóstico más preciso sin variables de estudio que afecten las observaciones como el cansancio o errores en la identificación de comportamientos específicos.

Esto, sin duda, es innovador en el área de investigación psicológica en entornos educativos, ya que aportará información valiosa en el área de investigación básica, así como en diagnóstico, prevención y atención de violencia escolar y *bullying*.

## Referencias

- AlMakadma, A. y Ramisetty-Mikler, S. (2015). Student, school, parent connect- edness, and school risk behaviors of adolescents in Saudi Arabia. *International Journal of Pediatrics and Adolescent Medicine*, 2, (3-4), 128-135.
- Beaudoin, H. y Roberge, G. (2015). Student perceptions of school climate and lived bullying behaviours. *Social and Behavioral Sciences*, 174, (12), 321-330.
- Bochkovski, A., Wang, C. Y. y Liao, H. Y. M. (Junio, 2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. En *2020 IEEE computer society conference on computer vision and pattern recognition (CVPR'20, Seattle, Washington, Estados Unidos)*. *arXiv preprint arXiv:2004.10934*.
- Brahnam, S., Roberts, J. J., Nanni, L., Starr y C. L. y Bailey, S. L. (Agosto, 2015). Design of a bullying detection/alert system for school-wide intervention. En *International conference on human-computer interaction (Los Angeles, California, Estados Unidos)*, Springer, Cham, 695-705.
- Cuenca, V. y Mendoza, B. (2017). Comportamiento Pro-social y agresivo en niños: Tratamiento conductual dirigido a Padres y Profesores. *Revista Acta de Investigación en Psicología*, 7, 2691-2703.
- Dalal, N. y Triggs, B. (Junio, 2005). Histograms of oriented gradients for human detection. En: *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05, San Diego, California, Estados Unidos)*, 886-893.
- Espinoza, E. (2006). Impacto del maltrato en el rendimiento académico. *Electronic Journal of Research in Educational Psychology*, 4, (9), 221-238.
- Fragkiadaki, K., Levine, S., Felsen, P. y Malik, J. (Junio, 2015). Recurrent network models for human dynamics. En *2015 IEEE computer society conference on computer vision and pattern recognition (CVPR'15, Boston, Massachusetts, Estados Unidos)*, 4346-4354.
- Gao, Y., Liu, H., Sun, X., Wang, C. y Liu, Y. (2016). Violence detection using oriented violent flows. *Image and vision computing*, 48, 37-41.
- Granic, I. y Patterson, G. (2006). Toward a comprehensive model of antisocial development: A dynamic systems approach, *Psychological Review*, 113, (1), 101-131.
- Giovazolias, T., Kourkoutas, E., Mitsopoulou, E. y Georgiadis, M. (2010). The relationship between perceived school climate and the prevalence of bullying behavior in Greek schools: implications for preventive inclusive strategies. *Social and Behavioral Sciences*, 5, 2208-2215.
- Girshick, R. (Junio, 2015). Fast r-cnn. En *2015 IEEE computer society conference on computer vision and pattern recognition (CVPR'15, Boston, Massachusetts, Estados Unidos)*, 1440-1448.
- Girshick, R., Iandola, F., Darrell, T. y Malik, J. (Junio, 2015). Deformable part models are convolutional neural networks. En *2015 IEEE computer society conference*



- on computer vision and pattern recognition (CVPR'15, Boston, Massachusetts, Estados Unidos), 437-446.
- Hendrickx M., Mainhard T., Boor-Klip H., Cillessen A. y Brekelmans M. (2016). Social dynamics in the classroom: Teacher support and conflict and the peer ecology. *Teaching and Teacher Education*, 53, 30-40.
- Idrees, H., Shah, M. y Surette, R. (2018). Enhancing camera surveillance using computer vision: a research note. *Policing: An International Journal*, 41, (2), 292-307.
- Li, L., Feng, X., Xia, Z., Jiang, X. y Hadid, A. (2018). Face spoofing detection with local binary pattern network. *Journal of visual communication and image representation*, 54, 182-192.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D. y Zitnick, C. L. (Septiembre, 2014). Microsoft coco: Common objects in context. En *European conference on computer vision (ECCV, Zurich, Suiza)*, Springer, Cham, 740-755.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y. y Berg, A. C. (Septiembre, 2016). Ssd: Single shot multibox detector. En *European conference on computer vision (ECCV, Munich, Alemania)*, Springer, Cham, 21-37.
- Mendoza, B., Delgado, I., y García, M.A. (2020). Student profile Not involved in bullying: description based on gender stereotypes, parenting practices, cognitive-social strategies and food over-intake. *Annals of Psychology*, 36 (3), 43-491.
- Mendoza, B. (2014). *Bullying: Los múltiples rostros del acoso escolar (2ª Ed.)*. Programa PRIMCE. Argentina: Editorial Brujas y Editorial Pax México.
- Mendoza, B. (2017). *Manual de Auto control de Enojo. Tratamiento Cognitivo-Conductual*. Cd. de México, México: Editorial Pax México.
- Mendoza, B. y Pedroza, F. (2015). Evaluación de un Programa de Intervención para Disminuir conducta disruptiva y Acoso Escolar. *Acta de Investigación Psicológica*, 5, (2), 1947-1959.
- Mendoza, B., Pedroza, F. y Martínez, K. (2014). Prácticas de Crianza Positiva: Entrenamiento a padres para reducir el Bullying. *Acta de Investigación Psicológica*, 4, (3), 1793- 1808.
- Mohamed, A. N. (Junio, 2015). A Novice Guide towards Human Motion Analysis and Understanding. En *2015 IEEE computer society conference on computer vision and pattern recognition (CVPR'15, Boston, Massachusetts, Estados Unidos)*, arXiv preprint arXiv:1509.01074.
- Ozkilic, R. y Kartal. H. (2012). Teachers bullied by their students: how their classes influenced after being bullied? *Social and Behavioral Sciences*, 46, 3435-3439.
- Patterson, G. (1982). *Coercive Family Process*, Eugene, O.R, Castalia.
- Povedano A., Cava M., Monreal M., Varela R. y Musitu, G. (2015). Victimization, loneliness, overt and relational violence at the school from a gender perspective. *International Journal of Clinical and Health Psychology*, 15, (1), 44-55.



- Redmon, J. (2016). Darknet: Open source neural networks. En: c. *Pjreddie. Com*.
- Redmon, J., Divvala, S., Girshick, R. y Farhadi, A. (Junio, 2016). You only look once: Unified, real-time object detection. En *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR'16, Las Vegas, Nevada, Estados Unidos)*, 779-788.
- Redmon, J. y Farhadi, A. (Junio, 2018). YoloV3: An incremental improvement. En *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR'18, Salt Lake City, Utah, Estados Unidos)*, *arXiv preprint arXiv:1804.02767*.
- Ren, S., He, K., Girshick, R. y Sun, J. (Diciembre, 2015). Faster r-cnn: Towards real-time object detection with region proposal networks. En: *Advances in neural information processing systems (NIPS, Montreal, Canadá)*, 91-99.
- Santoyo, C. (2009). Equity and reciprocity: Basic mechanisms of the organization of social behavior, *Journal of Behavior, Health & Social Issues*, 1, (2), 7-19.
- Santoyo, C. (2013). Aristas y Perspectivas Múltiples de la Ciencia del Desarrollo, en Carlos Santoyo (Coord.), *Aristas y Perspectivas múltiples de la investigación sobre desarrollo e interacción social*, México, UNAM, 107-132.
- Santoyo, C. y Mendoza, B. (2018). Behavioral Patterns of Children Involved in Bullying Episodes, *Frontiers in Psychology*, 1, 1-20.
- Subetha, T. y Chitrakala, S. (Febrero, 2016). A survey on human activity recognition from videos. En *2016 International Conference on Information Communication and Embedded Systems (ICICES, Chennai, Tamilnadu, India)*, 1-7.
- Thapa, A., Cohen, J., Higgins-D'Alessandro A. y Guffey, S. (2012). School Climate Research. *Summary. National School Climate Center*, 3, (3), 357-385.



El presente libro reúne una serie de investigaciones realizadas dentro de diversas áreas del conocimiento, contextos e instituciones. Expone un panorama actual de la educación mexicana en todos sus niveles centrándose en los ambientes de enseñanza, aprendizaje y análisis de problemáticas dentro del ámbito escolar.

Los autores, además de ser investigadores, también son profesores, lo que facilita su comprensión de las diferentes problemáticas a las que se enfrentan todos los días brindando alternativas de solución efectivas y acordes con el contexto en el que se desarrollan.

Es por ello que esta obra representa un esfuerzo importante y colaborativo por entender, debatir, dialogar y diagnosticar los procesos áulicos en los que intervienen diferentes actores y que son claves para la formación de los futuros profesionistas mexicanos.



Red de Centros Académicos  
en Investigación Educativa  
de la UAEM

RedCA

ISBN 978-607-437-593-0



9 786074 375930