

Tema A5 Educación: (Enseñanza asistida por inteligencia artificial)

“Explorando métricas afectivas y emocionales en aulas universitarias: un estudio de desarrollo y validación”.

Alejandro C. Ramírez Reivich*, Jorge Luis Pardo Gaytan, Diana Inés Ramírez García, María del Pilar Corona Lira ^a

^aCentro de Diseño Mecánico e Innovación Tecnológica, Universidad Nacional Autónoma de México, Cto. Exterior Ciudad Universitaria, Coyoacán, Ciudad de México, C.P. 04510, México.

*Autor contacto: areivich@unam.mx

RESUMEN

El presente artículo muestra los alcances de un estudio en proceso de desarrollo. Se plantea explorar soluciones a problemas relacionados con el comportamiento de los alumnos en aulas universitarias, con énfasis en la interacción alumno-profesor. Asimismo, se propone el empleo de herramientas provenientes de la Inteligencia Artificial, específicamente Deep Learning (Aprendizaje Profundo), así como técnicas basadas en la metodología de Diseño Centrado en el Usuario. Por medio de la identificación de diferentes comportamientos, se esboza el diseño conceptual de un sistema capaz de detectar factores que afecten el desempeño del alumno, mostrando información clave para impactar positivamente en los procesos de aprendizaje en los salones de clase. La observación y la exploración de las emociones involucradas en la asimilación e incorporación de conocimientos adquiridos, facilita desarrollar y validar métricas que cuantifiquen el nivel de interés y atención de los alumnos mediante la adquisición, procesamiento y análisis de sus expresiones faciales.

Palabras Clave: Reconocimiento de emociones, Expresión facial, Aprendizaje profundo.

ABSTRACT

This paper presents the scope of a study under development. This study aims to explore solutions to problems related to the behavior of students in university classrooms with an emphasis on student-teacher interaction. Data collection techniques based on the methodology of User-Centered Design will be used, as well as tools from Artificial Intelligence, specifically Deep Learning. Thereby, the conceptual design of a system capable of detecting factors that affect student performance is outlined. Furthermore, showing key information that positively influences learning processes through the identification of different behaviors in classrooms. The observation and exploration of emotions involved in the assimilation and incorporation of acquired knowledge makes easier the development and validation metrics. Moreover, through the acquisition, processing and analysis of their facial expressions it is intended to quantify the level of interest and attention of students.

Keywords: Emotion recognition, Facial expression, Deep Learning.

1. Introducción

Desde hace algunas décadas, estudios realizados en diferentes campos de conocimiento (que van desde la biología, las neurociencias hasta la filosofía, la psicología, la antropología y la sociología) han hecho hincapié en que las emociones constituyen un aspecto importante en la vida diaria, así como en su papel esencial en las interacciones efectivas tipo humano-humano [6]. El comportamiento no verbal transmite información afectiva y emocional para comunicar ideas, manejar interacciones y auxiliar en la transmisión del significado de las palabras para mejorar la eficiencia de las conversaciones [1]. Algunos estudios sostienen que el estudio de la comunicación no verbal por medio de las emociones, tiene

como origen las afirmaciones de Charles Darwin entorno a que las expresiones humanas de emoción evolucionaron en los humanos desde muestras no verbales pre-humanas [2]. Darwin es considerado como el primer pensador en sugerir la universalidad de las emociones y sus expresiones eran biológicamente innatas, evolutivamente adaptativas y que las similitudes existentes entre ellas podrían contemplarse dentro de un punto de vista filogenético [27]. Siguiendo esta idea, y de acuerdo a la descripción de Ekman [3,4] existen seis emociones básicas las cuales han adquirido un estatus especial dentro de la comunidad científica: enojo, disgusto, miedo, felicidad, tristeza y sorpresa. En gran medida, a partir de los últimos años se ha desarrollado un enfoque con miras a mejorar la interacción entre humanos y máquinas, y que a la vez, permita que esta relación sea producida de manera natural [7]. Una forma de

habilitar esta interacción natural, es permitiendo que una máquina reconozca el estado emocional de un usuario, empatice con él y sea capaz de crear respuestas adecuadas al estado del usuario [8]. Una vía de acceso para conseguir lo anterior es mediante el uso de la Inteligencia Artificial

Dentro del contexto de la Inteligencia Artificial, se enmarca el *Machine Learning* o Aprendizaje de Máquina, que tiene como principio el aprendizaje humano. La idea principal está basada en crear programas capaces de aprender información no estructurada en forma de ejemplos o mejor dicho, en la creación de modelos analíticos de forma automática. Uno de los enfoques más importantes del Aprendizaje de Máquina se le conoce con el nombre de Aprendizaje Profundo (conocido comúnmente como Deep Learning). El Aprendizaje de Máquina y el Aprendizaje Profundo en combinación con la proliferación de Big Data, presentan interesantes propuestas y soluciones a problemas que se presentan en varios campos de aplicación, sobre todo en lo referente a Visión por Computadora.

Aunque la mayoría de las ocasiones no nos percatemos de ello, el uso de la inteligencia artificial está presente en nuestra vida cotidiana, ya sea realizando mejoras en ella o facilitando ciertos aspectos de la misma. No obstante, hay ciertas áreas donde aún no se encuentra presente o tiene una presencia mínima. Una de estas áreas se localiza en el ámbito de la educación, particularmente en el salón de clases de cualquier nivel e institución educativa.

El presente proyecto plantea el uso de Inteligencia Artificial, especialmente, el Aprendizaje Profundo, para lograr un impacto significativo en materia de detección facial de emociones, no sólo para generar métricas del nivel de interés de los alumnos, sino también para observar y explorar las emociones involucradas en la asimilación e incorporación del conocimiento adquirido en el aula a través de la captura, procesamiento y análisis de sus expresiones faciales. Esto, nos permitirá definir secuencias de aprendizaje y vincularlas con elementos no verbales manifestados por los alumnos. Los datos recabados por este medio, serán relacionados y triangulados con los obtenidos mediante enfoques cualitativos de investigación social y diseño centrado en el usuario (como encuestas, entrevistas a profundidad, observación participante, prototipos, entre otras). Asimismo, se llevará a cabo la caracterización de algunas interacciones y de las secuencias de aprendizaje como resultado de las mismas.

Lo anterior permitirá profundizar en el conocimiento del desempeño del alumno, así como abordar ciertas problemáticas cuyas soluciones contribuyan a la mejora de puntos claves en el ámbito de la educación.

2. Trabajo relacionado

Enfoques tradicionales de Aprendizaje de Máquina como Máquinas de Soporte Vectorial y clasificadores Bayesianos han mostrado gran progreso hacia el reconocimiento de emociones. Sin embargo, muchos de ellos han surgido bajo situaciones y ambientes controlados. Esto, conlleva que dichos enfoques se encuentren limitados a expresiones muy similares a aquéllas que se encuentran en los datos de entrenamiento, por lo tanto presentan ciertas complicaciones para clasificar imágenes capturadas “al natural” o tomadas de grabaciones de videos en tiempo real [13]. Las imágenes “al natural” son espontáneas y normalmente se caracterizan por ofrecer diferentes ángulos, poses, numerosas condiciones de iluminación, niveles de oclusión, etc.

Por tanto, el reconocimiento de emociones “al natural” resulta un campo activo y desafiante para la academia, debido tanto a la falta de grandes cantidades de datos etiquetados y clasificados como a la variedad de condiciones en la cual cada imagen es tomada. Los datasets de emociones faciales existentes, tienden a poseer un número fijo de sujetos de prueba o un cierto número de imágenes por expresión con una pequeña variación entre datasets. Estos conjuntos de datos son utilizados para entrenar a los modelos a emplear en cuestión de reconocimiento de expresiones faciales. Es común encontrar que se utilicen datasets de expresiones faciales públicos tales como MultiPIE, MMI, CK+, DISFA, FERA, SFEW, FER2013 [13], KDEF [26] entre otros. Así, se debe tomar en cuenta que normalmente los datasets de prueba y entrenamiento, contienen imágenes de calidad similar y tomadas bajo ambientes controlados. Raramente se puede encontrar un dataset que incluya una amplia variedad de condiciones ambientales, condiciones de iluminación y sujetos de prueba tomados en condiciones “al natural”.

Desde hace algunos años, el reciente crecimiento del Aprendizaje Profundo con las Redes Neuronales, ha generado un progreso prometedor no solo en el campo del reconocimiento facial y de sus emociones, sino en varias áreas de interés tanto para la industria como para la academia. La capacidad de las Redes Neuronales de extraer características no definidas, permite a las mismas generalizar de una manera más óptima hacia escenarios desconocidos. Una Red Neuronal Profunda puede ser aplicada exitosamente para clasificar imágenes distintas de las originales, para las cuales fue entrenada [14].



**Figura 1- Muestra de imágenes del KDEF dataset [26].
La mujer muestra 7 emociones: tristeza, sorpresa, neutralidad,
felicidad, miedo, disgusto y enojo.**

Se pueden encontrar distintos tipos de enfoques y acercamientos a partir de Redes Neuronales, pero particularmente aquellas propuestas que utilizan Redes Neuronales Convolucionales (Convolutional Neural Networks o CNN) han resultado sumamente exitosas en los últimos años, particularmente en tareas relacionadas con imágenes debido a su habilidad para extraer buenas representaciones y características de los datos provistos. [5]

Los modelos registrados en el estado del arte, presentan altas tasas de precisión como la propuesta por Andre Texeira Lopes et al. [15]. Usando una Red Neuronal Convolutional Profunda para clasificar expresiones faciales, el estudio de dicho autor obtuvo una precisión del 97.81%. También existen otros modelos que eliminan otras dificultades de las redes neuronales, como el propuesto por Lu Guanming et al. [17], el cual plantea un modelo para reconocimiento de expresiones faciales que hace uso de estrategias como el dropout y la expansión del dataset para resolver tanto el problema de datos de entrenamiento insuficientes como la cuestión del overfitting.

3. Modelo propuesto

En la actualidad, una de las estrategias para la implementación de una aplicación de aprendizaje de máquina consiste en lo siguiente:

- a) Se busca una base de datos que tenga relación con el problema planteado.
- b) Se selecciona el modelo que se utilizará para llegar a una solución obtenida con la base de datos seleccionada.
- c) Se realizan las pruebas y se establece una solución.

El uso de esta metodología afecta totalmente el cómo abordar un problema que sea diferente a uno con miras a mejorar el desempeño del modelo de redes neuronales como tal. La vía mencionada limita las soluciones que se pueden obtener con la base de datos, por lo que normalmente, esto no es una solución alineada a las necesidades humanas.

De tal forma, si se coloca un problema relacionado a una necesidad del usuario y se genera un dataset alineado con el problema encontrado, por consiguiente, el modelo de aprendizaje profundo estará propuesto con el fin de dar una solución al problema encontrado.

Con lo anterior, es posible generar una herramienta muy poderosa para afrontar el problema y tener una solución centrada en el usuario (alumno), permitiendo que ésta encierre un gran efecto positivo y sea capaz de producir un cambio disruptivo en la forma en que actualmente se imparten las asignaturas en el aula.

El alcance del proyecto no es generar un nuevo modelo de aprendizaje profundo innovador o que el sistema compita con los modelos del estado del arte actuales, sino la aplicación del enfoque de diseño centrado en el usuario aunado a la tecnología del aprendizaje profundo para atacar un problema relacionado con una necesidad humana, y de esta forma, cambiar radicalmente la experiencia del individuo con el uso de estas dos herramientas, mismas que pueden generar un excelente resultado al ser utilizadas en conjunto.

3.1. Redes Neuronales Profundas para reconocimiento de emociones.

Tensorflow es la segunda generación de Investigación y Desarrollo de Inteligencia artificial desarrollado por Google [10]. Esta plataforma soporta Redes Neuronales Convolucionales (CNN), Redes Neuronales Recurrentes (RNN) y otros modelos de redes neuronales. Esta plataforma es ampliamente usada en productos y servicios de Google, y ha sido desplegada en más de 100 proyectos de Aprendizaje de Máquina envolviendo campos de aplicación como reconocimiento de habla, visión por computadora, robótica, retribución de información, extracción de información, procesamiento de lenguaje natural y pruebas de medicamentos [11].

Se decidió recurrir a un sistema de reconocimiento donde se pudiera tener acceso al código y modificarlo, en lugar de utilizar APIs disponibles como Emotion[19] de Microsoft o el API de Google llamado Cloud Vision[20]. La razón se debe a que permite una mayor flexibilidad en cuestión de inspeccionar y manejar ciertos elementos para incrementar la precisión del modelo y tener un mayor control y flexibilidad en el mismo.

En el primer acercamiento se utilizó la base de datos de FER2013 [18]. Este dataset contiene 3761 imágenes en escala de grises de un tamaño de 48 x 48 píxeles. Las imágenes contienen de 5 a 7 clases de expresiones. Además de las clasificadas por Ekman, se agrega la etiqueta de neutral. Para este acercamiento se usó una red neuronal no profunda de 3 capas convolucionales para probar el funcionamiento. La aproximación fue útil para ver cómo al cambiar gradualmente parámetros como los ciclos de entrenamiento (o épocas), la tasa de aprendizaje o el tamaño del batch, puede a la vez, modificar paulatinamente la precisión del modelo o afectar el overfitting. En este caso, Overfitting significa que el modelo aprendió detalles y ruido de los datos de entrenamiento, lo que ocasiona un sesgo en el modelo y no permite la generalización, es decir, aprender las características necesarias para tener buenos resultados en imágenes que no ha visto el modelo.

Los resultados obtenidos en esta primera fase no fueron del todo satisfactorios, por tanto, se optó por partir de un modelo previamente entrenado con buenos resultados y aplicar Transfer Learning (Transferencia de conocimiento) para nuestra aplicación.

3.2. Transferencia de conocimiento

En la práctica, muy pocas personas entrenan una red convolucional desde cero (con inicialización aleatoria), debido a que es relativamente raro tener una dataset de suficiente tamaño. Así, en vez de entrenar desde cero, es común pre-entrenar una red convolucional en un dataset muy grande (por ejemplo ImageNet [25], el cual contiene 1.2 millones de imágenes con mil categorías) y después utilizarlo como extractor de características para la tarea de interés. [21]. La meta de la transferencia de conocimiento es aplicar el conocimiento aprendido en el entrenamiento de un ambiente anterior hacia uno nuevo. [11]

En este caso, se usará en la transferencia de conocimiento el modelo Inception-v3. Este modelo está entrenado en el dataset de ImageNet, conteniendo información con la posibilidad de catalogar mil clases donde la tasa de error fue de 3.5% en el top-5 [22]. Este modelo es el sucesor de Inception-v1 [24] e Inception-v2 [23], ambos desarrollados por Google. El modelo Inception-v3 tiene un clasificador de 1000 clases o etiquetas, razón por la cual se requiere eliminar la última capa del modelo y añadir una nueva, misma que deberá entrenarse de acuerdo con las necesidades del estudio. En este caso, significa que serán inicialmente 7 etiquetas las que clasificarán el modelo Inception-v3 re-entrenado y afinado. Se trata de un modelo que será entrenado con el dataset que se encuentra en proceso de recolección.

3.3. Creación de "dataset"

La muestra considerada en el trabajo está constituida por alumnos universitarios que cursan los primeros semestres de la Facultad de Ingeniería de la UNAM. Por esta razón, el dataset del proyecto se encuentra en proceso de creación con datos obtenidos de un laboratorio de diseño, lugar que posibilita mantener un mayor control sobre ciertas variables y detectar puntos clave de la experiencia de usuarios (alumnos) en un ambiente de estudio y de impartición de clases. Por otro lado, también se lleva a cabo un proceso de retroalimentación con base en entrevistas aplicadas a estudiantes seleccionados al azar.

Las entrevistas son grabadas (con consentimiento del alumno) y analizadas para obtener información de corte cualitativo útil para el estudio y de gran ayuda para el entrenamiento del modelo de Aprendizaje Profundo. El número de etiquetas (emociones) a clasificar pueden ser modificadas de acuerdo al avance en la creación del dataset

y de los posibles hallazgos que encuentre el equipo de diseño durante el proceso.

En el primer diseño del dataset se realizaron tomas individuales de los alumnos, grabando una cierta cantidad de minutos (cantidad de tiempo establecida conforme a métricas acordadas por el equipo de diseño) dependiendo de la forma en cómo se vayan generando las reacciones de los alumnos y las posibles características que sean de interés para el estudio.



Figura 2- Muestra de imágenes de las entrevistas exploratorias. Los alumnos muestran 5 emociones: desconcierto (tristeza), sorpresa, neutralidad, felicidad y disgusto.

Después de tomar los vídeos, se necesita realizar un pre-procesamiento de las imágenes, es decir, convertir el vídeo en imágenes con un formato compatible con el modelo de Aprendizaje Profundo.

En un análisis previo al pre-procesamiento, se examinan los vídeos para encontrar y detectar ciertas imágenes que podrían no ser útiles para el modelo, además de que es posible encontrar ciertos detalles o características que no se habían previsto o también simplemente afirmar ciertas hipótesis o supuestos del equipo de diseño.

En este análisis previo, resulta de gran ayuda el empleo de técnicas de pre-procesamiento pues permiten mejorar el rendimiento general del modelo. Entre varias técnicas podemos encontrar el realce de la calidad de las imágenes, la reducción del tamaño de la imagen, detección y recorte de caras, entre otras; y su uso es de gran utilidad para lograr disminuir el tiempo de procesamiento de cómputo.

Cabe señalar que este proceso no solamente ayuda a mejorar el modelo, sino que también afecta indirectamente a la optimización del estudio en general, ya que tanto el análisis previo como el pre-procesamiento son tareas muy laboriosas y consumen bastante tiempo.



Figura 3- Imágenes de videos tomados en el aula como simulación del Procesamiento del modelo.

En determinados momentos del proyecto, resultará necesario llevar a cabo una evaluación del modelo para conocer su desempeño y analizar formas de mejorarlo. Por tanto, no solamente se planea la evaluación del modelo de Aprendizaje Profundo, sino también la revisión constante del estado del estudio y la verificación de que éste siga alineado con las necesidades del alumno. Después de cada evaluación, se irán añadiendo los datos que se recolectaron en el último ciclo, con lo cual se incrementará la cantidad de información del dataset, y con ello, la posibilidad de obtener un mejor entrenamiento como resultado de las valoraciones.

Uno de los problemas más difíciles de resolver en el Aprendizaje Profundo -que no tiene nada que ver con las redes neuronales- es la dificultad de obtener los datos correctos en el formato adecuado [16]. Por consiguiente, se buscará la actualización continua de la base de datos creada para seguir mejorando el desempeño general tanto del modelo como del estudio.

En la fase final del estudio se estimará si los parámetros tomados para la creación del dataset son los óptimos, así como las posibles áreas de oportunidad para mejorar tanto el desempeño del estudio como los patrones de interés y el desempeño del modelo de aprendizaje profundo

4. Conclusiones y trabajo a futuro

Las posibilidades de implementación y mejora de este tipo de tecnologías son grandes si nos alineamos a las necesidades humanas. En nuestro caso, por ejemplo, se plantea la oportunidad de generar a futuro un “historial” de aprendizaje de cada alumno para dar seguimiento para proveerlos de herramientas personalizadas de acuerdo a sus necesidades. Gracias a las técnicas de Aprendizaje Profundo sería posible tener un acercamiento más personal cuando se detecte que el alumno tiene ciertas actitudes que ameritan ser potencializadas o redirigidas o cuando éste muestre un patrón de tristeza o alguna actitud negativa en su día a día en el salón de clases.

Mediante esta personalización y seguimiento de los alumnos, sería probable advertir casos de depresión, de mala alimentación, o de abuso, posibilitando a cada institución educativa brindar ayuda donde fuera posible, es decir, canalizar al alumno a servicios profesionales capaces de atender su problemática para que su aprovechamiento académico no se ve afectado. Además de ayudar a la comunidad académica a entender las causas del porqué existen ciertas actitudes en los alumnos hacia la planta académica y, de este modo, enriquecer la relación y comunicación entre alumno-profesor.

Adicionalmente, en un trabajo a futuro, se explorará la posibilidad de utilizar diferentes enfoques y propuestas, además de incorporar variables de entrada como señales de voz, lenguaje corporal, ECG y otras señales fisiológicas en el modelo. Con una correcta medición de ciertas variables fisiológicas, se abre la posibilidad de obtener una mejor representación de las emociones y de las tasas de precisión en el reconocimiento de ellas, ayudando a establecer una detección más precisa del estado afectivo del alumno.

Se espera que esta investigación pueda contribuir a que la enseñanza asistida por Inteligencia Artificial esté a un paso más cerca de ser aceptada socialmente en el sistema educativo a un corto plazo.

Agradecimientos

Este trabajo de investigación es realizado con el apoyo del Programa UNAM-DGAPA-PAPIME PE 111118 “Observación y exploración de las emociones generadas en el proceso de aprendizaje a través del estudio de las facciones faciales”. Asimismo, agradecemos a los estudiantes que participaron en las entrevistas y grabaciones.

REFERENCIAS

- [1] Jessica L Tracy, Daniel Randles, and Conor M Steckler. 2015. The nonverbal communication of emotions. *Current Opinion in Behavioral Sciences* 3 (2015), 25– 30. DOI: <http://dx.doi.org/10.1016/j.cobeha.2015.01.001> Social behavior.
- [2] Charles Darwin. 1872/2009. *The Expression of the Emotions in Man and Animals* (anniversary ed.). Harper Perennial. <http://www.worldcat.org/isbn/0195158067>
- [3] Paul Ekman. 1992. An argument for basic emotions. *Cognition and Emotion* (1992), 169–200.
- [4] Paul Ekman and Wallace V. Friesen. 1971. Constants across cultures in the face and emotion. *Journal of Personality and Social Psychology* 17, 2 (1971), 124–129.
<http://search.ebscohost.com/login.aspx?direct=true&db=psp&AN=psp-17-2-124&site=ehost-live>
- [5] Yoshua Bengio Ian Goodfellow and Aaron Courville. 2016. *Deep Learning*. (2016). <http://goodfeli.github.io/dlbook/> Book in preparation for MIT Press.
- [6] Lewis, M., Haviland-Jones, J., Barrett, L.: *Handbook of Emotions*. Guilford Press, New York (2008)
- [7] Chavhan, A., Chavan, S., Dahe, S., Chibhade, S.: A neural network approach for real time emotion recognition. *IJARCCCE* 4(3), 259–263 (2015)
- [8] Han, K., Yu, D., Tashev, I.: Speech emotion recognition using deep neural network and extreme learning machine. In: *Interspeech*, pp. 223–227 (2014)
- [9] Ruiz García, A., Elshaw, M., Altahan, A., Palade, V. *Deep Learning for Emotion Recognition in Faces*.
- [10] Martín Abadi, Ashish Agarwal, et al: *Tensor Flow: Large-Scale Machine Learning on Heterogeneous Distributed Systems*. CoRR abs/1603.04467 (2016)
- [11] Xia, X., Xu, C., Nan, B. Facial Expression Recognition Based on Tensorflow Platform. (2017) ITM Web of Conferences.
- [12] Lundqvist, D., Flykt, A., Ahman, A.: *The Karolinska Directed Emotional Faces KDEF*. CD ROM from Department of Clinical Neuroscience, Psychology section, Karolinska Institutet (1998). ISBN 91-630-7164-9
- [13] Rao, P., Li, L. Facial Expression Recognition for Wild Images with Analysis from Saliency Maps.
- [14] Mollahosseini, Ali, David Chan, and Mohammad H. Mahoor. "Going deeper in facial expression recognition using deep neural networks." *Applications of Computer Vision (WACV)*, 2016 IEEE Winter Conference on. IEEE, 2016.
- [15] Teixeira A., Aguiar E., Oliveira-Santos, T.: A Facial Expression Recognition System Using Convolutional Networks. *SIBGRAPI* 2015: 273-280
- [16] Zaccane G., Karim R., Menshawy, A. (2017) *Deep Learning with Tensorflow*. Packt Publishing. ISBN 978-1-78646-978-6
- [17] Lu Guanming, Shi Wanwan, Li Xu, et al: A kind of convolution neural network for facial expression recognition
- [18] Facial Expression Recognition Challenge 2013 dataset. <https://www.kaggle.com/c/challenges-in-representation-learning-facial-expression-recognition-challenge/data>
- [19] Microsoft Azure. Emotion API. <https://azure.microsoft.com/en-us/services/cognitive-services/emotion/>
- [20] Google. Cloud Vision API. <https://cloud.google.com/vision/?hl=es-419>
- [21] CS231n Convolutional Neural Networks for Visual Recognition <http://cs231n.github.io/transfer-learning/>
- [22] Christian Szegedy, Vincent Vanhoucke, et al: Rethinking the Inception Architecture for Computer Vision. arXiv:1512.00567, 2015.
- [23] Sergey Ioffe, Christian Szegedy, et al: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *ICML2015*: 448-456, 2015.
- [24] Christian Szegedy, Wei Liu, et al: Going Deeper with Convolutions. arXiv:1409.4842, 2014.
- [25] ImageNet Stanford Vision Lab. <http://www.image-net.org/>
- [26] Lundqvist, D., Flykt, A., Ahman, A.: *The Karolinska Directed Emotional Faces -KDEF*. CD ROM from Department of Clinical Neuroscience, Psychology section, Karolinska Institutet (1998). ISBN 91-630-7164
- [27] Matsumoto, David; Sung Hwang, Hyi; López M., Rafael; Pérez-Nieto, Miguel Ángel (2013): *Lectura de la Expresión facial de las emociones: investigación básica en la mejora del reconocimiento de las emociones*, en *Ansiedad y Estrés*, 19(2-3), pp. 121-129.
- [28] Cedillo, Priscila; García-Andrade, Adriana; Sabido, Olga (2016): "Afectividad y emociones", en Moreno Hortensia y Alcántara Eva (Coords.), *Conceptos clave en los estudios de género. Volumen I*, Programa Universitario de Estudios de Género, UNAM, México, pp. 15-33.