

Maniobra Gowers utilizando redes convolucionales con videos

Baldo Alberto Campos Leal, Julia Díaz Escobar, Alan Díaz Montiel, Verónica Quintero Rosas,
Gabriel Lee Álvarez, Mario Alberto Camarillo Ramos

Departamento de Sistemas y Computación, Tecnológico Nacional de México/ Instituto Tecnológico de Mexicali, Av. Tecnológico s/n, Col. Elías Calles, Mexicali BC, 21376

Resumen

El signo de Gowers es un síntoma visual que presentan muchas distrofias neuromusculares, incluida la distrofia muscular de Becker, la distrofia muscular congénita, la miopatía congénita y la distrofia muscular de Duchenne, que es la más agresiva, con una esperanza de vida de 20 a 30 años. Además, existe una brecha de 2.5 años entre la aparición de los síntomas iniciales y un diagnóstico confirmado. La detección temprana permite el tratamiento de la enfermedad, lo que conduce a una mejor calidad de vida. Hasta donde sabemos, aún no se ha propuesto un sistema de visión por computadora no invasivo para detectar el signo de Gowers. Este trabajo de investigación tiene como objetivo demostrar que las redes convolucionales con redes recurrentes pueden detectar eficazmente la maniobra del Signo de Gowers en niños de 3 a 6 años. Para lograr esto, creamos una base de datos de videos con dos clases: una con la maniobra del Signo de Gowers y otra sin ella. Dado que los videos recopilados de varias fuentes tienen diferentes resoluciones, empleamos un método llamado relleno para evitar distorsiones causadas por el cambio de tamaño y escalado durante el procesamiento de la red convolucional. El modelo propuesto logra una precisión de detección del 94%, una precisión del 90%, una recuperación del 100% y una puntuación F1 del 94% sin relleno en los videos.

Abstract

Gowers' Sign is a visual symptom exhibited by many neuromuscular dystrophies, including Becker muscular dystrophy, congenital muscular dystrophy, congenital myopathy, and Duchenne muscular dystrophy, which is the most aggressive, with a life expectancy of 20 to 30 years. Additionally, there is a 2.5-year gap between the onset of initial symptoms and a confirmed diagnosis. Early detection allows for the treatment of the disease, leading to a better quality of life. To the best of our knowledge, a non-invasive computer vision system for detecting Gowers' Sign has not yet been proposed. This research paper aims to demonstrate that convolutional networks with recurrent networks can effectively detect the Gowers' Sign maneuver in children aged 3 to 6 years. To achieve this, we created a video database with two classes: one with the Gowers' Sign maneuver and one without. Since the videos collected from various sources have different resolutions, we employed a method called padding to prevent distortions caused by resizing and rescaling during the convolutional network processing. The proposed model achieves a detection accuracy of 94%, precision of 90%, recall of 100%, and an F1 score of 94% without padding in the videos.

Palabras Clave: Signos de Gowers, Distrofia muscular de Duchenne, Redes neuronales convolucionales, aprendizaje automático

Keywords: Gowers' Sign, Duchenne muscular dystrophy, Convolutional Neural Networks, Machine Learning

1. INTRODUCCIÓN

EL correcto desarrollo de un niño es de crucial importancia. Los hitos del desarrollo son habilidades que permiten detectar el desarrollo normal y anormal de un niño desde el nacimiento hasta aproximadamente los cinco años [1]. Estas habilidades incluyen sonreír por primera vez y dar el primer paso, entre otras. Los niños alcanzan hitos hablando, moviéndose, jugando y aprendiendo. Un problema crítico del desarrollo, que suele observarse alrededor de los 18 meses de edad, es la capacidad de caminar bien y realizar movimientos como levantar la cabeza, sentarse o pararse sin ayuda. Esta condición se conoce como signo de Gowers, un síntoma común de debilidad de los músculos proximales, particularmente en las extremidades inferiores [2].

El Signo de Gowers es un síntoma que aparece consistentemente en diferentes distrofias neuromusculares; por ejemplo, Distrofia Muscular de Duchenne (DMD), distrofia muscular de Becker, distrofia muscular congénita, miopatía congénita, entre otras [3]. Al estar presente en diferentes problemas de salud, es crucial detectar el Signo de Gowers lo antes posible para brindarle al paciente el mejor trato que el paciente puede recibir.

La DMD es un trastorno genético que causa debilidad muscular y rigidez en la cintura. La DMD empeora con el tiempo, afectando brazos y piernas y provocando problemas respiratorios y cardíacos, que pueden ser mortales. Si bien es una de las muchas distrofias neuromusculares, la DMD es la más conocida y prevalente, y afecta a uno de cada 3500 recién nacidos en todo el mundo. Actualmente, no existe cura para la DMD, pero con un diagnóstico precoz y un tratamiento adecuado se puede prolongar la esperanza de vida. En 1960, las personas con DMD tenían una esperanza de vida de hasta 14 años. Sin embargo, a partir de 2022, la esperanza de vida ha aumentado a 25-30 años, gracias a la detección temprana y a las intervenciones médicas. [4] [5] [6].

Los procedimientos de diagnóstico de DMD más comunes son la biopsia muscular, el análisis de sangre, el recuento de creatina fosfoquinasa (CPK) y las pruebas genéticas. En México, estas pruebas pueden costar hasta MXN 5,000.00 pesos (USD 300.00), lo cual es costoso para la mayoría de la población. En consecuencia, la intervención temprana es inexistente y las personas con DMD fallecen a los 19 años [7]. El enfoque más eficaz para prolongar la esperanza de vida es mediante la detección temprana, que puede iniciarse en función de la aparición temprana de los síntomas de DMD que normalmente se observan entre las edades de 3 a 6 años [8] [9] [10].

La maniobra del signo de Gowers se realiza levantándose desde boca abajo, en decúbito supino, agachado o sentado en el suelo. Dado que la mayoría de las distrofias neuromusculares causan debilidad muscular, los individuos no pueden levantar el tronco sin usar las manos y los brazos para apoyarse y empujar. Por lo tanto, después de acostarse, un individuo rueda hasta quedar boca abajo, empuja el suelo y estira las piernas para formar un triángulo con los pies y las manos en el suelo. Luego se mueven las manos hasta las rodillas para levantar el tronco. Finalmente, se utilizan las manos para trepar por las piernas hasta mantenerlas erguidas. Este movimiento se ilustra en la Figura 1. Es posible que los niños con casos más leves de esta afección de salud no requieran el uso de las manos para ponerse de pie [11].



Figura 1. Etapas de la maniobra del signo de Gowers

Este artículo presenta un modelo diseñado para la detección temprana de la maniobra del signo de Gowers utilizando algoritmos de aprendizaje automático (ML). El modelo toma imágenes extraídas de videos como entrada y emplea redes neuronales convolucionales (CNN) para el reconocimiento de imágenes. Además, la incorporación de redes recurrentes permite el análisis de datos secuenciales. Al combinar ambos

componentes, el modelo puede evaluar datos de imágenes secuenciales para determinar si un niño presenta una anomalía en su capacidad para ponerse de pie. Además, este modelo propuesto se puede integrar en un sistema de Internet de las cosas (IoT) para la detección en tiempo real. Los resultados de nuestro método demuestran una precisión del 95% para la detección temprana de la maniobra del Signo de Gowers. Hasta donde sabemos, ningún otro artículo en la literatura ha informado anteriormente sobre un modelo similar.

El resto del documento está organizado como sigue. La Sección II presenta el trabajo relacionado. La Sección III analiza los materiales y métodos utilizados en este trabajo. La Sección IV presenta los resultados y la discusión. Finalmente, la Sección V es para las conclusiones y el trabajo futuro.

2. DESARROLLO

2.1 Recolección de datos

Niños con distrofia muscular: 74 videos se obtuvieron de YouTube, Vimeo, Dailymotion, entre otras fuentes. Estos videos tienen diferentes características. Su resolución va de 240p a 720p. La duración de los videos varía de 3 a 15 segundos y muestra diferentes etapas de la enfermedad neuromuscular. Los ángulos de visión varían; Los videos se grabaron en un espacio controlado y sin estabilización, agregando que fueron grabados desde una vista frontal, lateral o superior. Algunos videos se grabaron en modo horizontal y otros en modo vertical. Hay muchos escenarios diferentes.

Niños sanos: Los videos de niños sanos no supusieron ningún problema. Algunos videos fueron tomados de Internet y otros fueron grabados por nosotros. En total, son 74 videos de niños sanos. En esta categoría hay 15 niños diferentes. La resolución también varía de 240p a 720p. Fueron grabados desde diferentes perspectivas para imitar el comportamiento de los niños con categoría de distrofia muscular, y se utilizaron dos cámaras: un teléfono inteligente OnePlus 9, configurado con una resolución de 720p y 30 cuadros por segundo, y una cámara web de computadora portátil, configurada con una resolución de 720p y 30 fotogramas por segundo. Se pidió a los niños que intentaran hacer los movimientos (levantarse desde boca abajo, en decúbito supino, agacharse o sentarse en el suelo) rápida y lentamente para que pudiéramos imitar el comportamiento de la otra categoría. También hubo diferentes escenarios. La figura 2 muestra un ejemplo de imágenes de un niño sano de pie.

En todos los videos recopilados de diferentes fuentes que fueron grabados por nosotros aparecen niños de entre 3 y 6 años.



Figura 2. Ejemplo de movimientos infantiles saludables

2.2 Construyendo la base de datos

La base de datos original tiene dos categorías, etiquetadas como problema y no problema. La categoría problema contiene videos de pacientes que presentan la maniobra del signo de Gowers. Sin embargo, no se

muestra qué distrofia muscular tienen estos niños. La categoría sin problemas contiene vídeos de niños que no muestran el signo de Gowers al ponerse de pie. El primer paso fue separar la base de datos en conjuntos de entrenamiento y prueba. Se seleccionaron al azar catorce vídeos de cada categoría para realizar pruebas y los 60 vídeos restantes de cada categoría se eligieron para el conjunto de entrenamiento.

La primera base de datos, denominada V1, contiene los vídeos originales sin modificaciones. La base de datos V1 tiene 120 vídeos y cada categoría tiene 60 vídeos.

La segunda base de datos, denominada V2, contiene los vídeos originales modificados con relleno (se explica más a continuación). En total, la base de datos V2 tiene 120 vídeos, de los cuales cada categoría tiene 60 vídeos. La tercera base de datos, denominada V3, contiene los vídeos modificados con relleno y los dos métodos de aumento de datos seleccionados (a saber, ruido gaussiano y sal-pimienta). La base de datos V3 tiene 360 vídeos y cada categoría tiene 180 vídeos. La base de datos de prueba contiene 14 vídeos no modificados que no presentan problemas y 14 vídeos no modificados que presentan problemas, y hubo dos versiones, una sin modificaciones y otra con relleno.

2.3 Adición de relleno

Al buscar vídeos de niños realizando la maniobra del signo de Gowers, encontramos diferentes resoluciones en diferentes plataformas, incluidas 360p, 480p, 720p e incluso 1080p. Sin embargo, al insertar una imagen en la red convolucional, surgieron problemas debido al cambio de tamaño y escala necesarios para la entrada de la red. Este proceso provocó distorsiones y pérdida de la representación precisa de la imagen durante la clasificación. Para abordar este problema, se empleó un método llamado "relleno de ceros". Este método implica agregar píxeles con valores cero a los bordes de la imagen. Como resultado, el vídeo mantiene una forma cuadrada, lo que garantiza que, al cambiar el tamaño, la imagen conserve su representación precisa sin distorsión.

2.4 Aumento de datos

Al comienzo de los experimentos, la base de datos contenía sólo 148 vídeos, que debían mejorarse para entrenar un modelo de red neuronal. Por este motivo, se utilizaron técnicas de aumento de datos para simular una base de datos más extensa, mejorando así la fase de entrenamiento y el rendimiento del modelo.

Se utilizó la clase ImageDataGenerator de la biblioteca Keras [12] para realizar las técnicas de aumento de datos. Los métodos utilizados fueron rotación, zoom, traslación, volteo y Adición de ruido, con las siguientes configuraciones:

Para voltear, se usó el parámetro de giro horizontal y solo se usó el giro horizontal, dando el valor Verdadero.

- Para la rotación, el parámetro utilizado fue el rango de rotación y se dio una variación de 8 grados.
- Para la traducción, se utilizó el desplazamiento de ancho y el desplazamiento de altura para mover la imagen en los ejes 'x' e 'y', respectivamente, con un valor de 0,2 para cada uno.

2.5 Adición de ruido

Incorporar ruido como método de aumento de datos puede resultar un desafío al agregarlo a una base de datos. Muchas redes neuronales suelen aplicar filtrado de imágenes para reducir los niveles de ruido tanto como sea posible antes de insertar la imagen en la red.

Sin embargo, la introducción de ruido como técnica de aumento de datos mejora principalmente el volumen del conjunto de datos. Además, se ha establecido que las redes neuronales son susceptibles a los efectos del ruido [13]. Además, se ha demostrado que entrenar una red neuronal con ruido permite que el modelo se generalice mejor [14].

Cuando el sistema procesa un lote de imágenes, se introduce ruido. Sin embargo, el objetivo es aumentar la cantidad de datos. Por lo tanto, se decidió utilizar dos etapas de ruido diferentes en la base de datos original. A los 60 vídeos de cada categoría de la base de datos original se les aplicó una etapa de ruido gaussiano con una desviación estándar de $0,07 \times 255$ y otra etapa de ruido sal-pimienta con un porcentaje del 5% sobre todos los píxeles de la imagen. Así, en la Tabla 1 se muestran 180 vídeos de cada categoría.

Tabla 1. Estructura para la base de datos V3

Videos	Cantidad
Original	60
Ruido gaussiano	60
Ruido sal-pimienta	60
Total	180

2.6 Construcción del modelo

El modelo propuesto utiliza vídeos como entrada para clasificar como en [15]. Posteriormente, los vídeos se separan en secuencias de diferentes imágenes. Para luego clasificar cada uno de ellos, considere el orden en que se inserta la secuencia. Para ello se fueron utilizadas otras técnicas de redes neuronales.

- 1) **Red neuronal convolucional:** las CNN [16] se utilizan para el reconocimiento de imágenes, el reconocimiento de patrones y la visión por computadora. Para nuestros experimentos se utilizó MobileNet ya que es un modelo eficiente, liviano y no requiere mucha computación, lo que significa que se puede integrar fácilmente en un dispositivo móvil. De esta solo se tomaron las capas convolucionales para integrarlo en el sistema y se eliminaron las capas completamente conectadas.
- 2) **Red neuronal recurrente:** GRU [16]. Estas redes son muy similares a las redes LSTM, que también se crearon para solucionar el problema de la memoria. En este caso, existen dos puertas, una de restauración (reset) y otra de actualización (update). Controlando así qué información se guarda y qué datos se olvidan. Usamos redes GRU para nuestro modelo.
- 3) **Generador de fotogramas de vídeo:** Keras proporciona un generador de cuadros diseñado para conjuntos de datos de imágenes. Esta clase agiliza el proceso de aumento de datos utilizando parámetros específicos, generando múltiples imágenes en forma de lotes. Sin embargo, surge un desafío cuando el sistema necesita operar no solo con imágenes individuales sino también con secuencias de imágenes (vídeos) para hacer predicciones. Para abordar este problema, se desarrolló un generador de fotogramas de vídeo especializado.
- 4) **Capa distribuida en el tiempo:** Normalmente, con redes convolucionales, ingresamos una imagen y recibimos una predicción para esa imagen específica. Sin embargo, cuando se trata de una secuencia de imágenes, el objetivo es identificar las acciones realizadas por un objeto a lo largo del tiempo. El desafío surge cuando necesita proporcionar al modelo una secuencia de imágenes como entrada, como se discutió por Feleta et al. [17]. Si utilizara una red convolucional estándar, necesitaría fusionar todas las imágenes en una sola convolución, lo que difiere del enfoque deseado. Debe alimentar el

modelo una imagen a la vez como si cada imagen tuviera su propia red convolucional (aunque es la misma red utilizada en diferentes pasos de tiempo).

Cada imagen dentro de una secuencia produce una salida que se enviará a la red recurrente una vez que todas las imágenes de la secuencia pasen por la red convolucional. Una vez esto

Una vez finalizado el proceso, la secuencia obtenida se puede transferir a la red LSTM o GRU recurrente.

5) **Hiperparámetros del modelo:** Los hiperparámetros utilizados en el modelo se muestran en la Tabla 2.

Tabla 2. Hiperparámetros utilizados para el modelo

Parámetros	Valor
Tamaño de la imagen	(224, 224)
canales de imagen	3
Imágenes por secuencia	5
Tamaño del lote	8
Optimizador	SGD
Función de pérdida	categorical crossentropy
Epochs	10

3. RESULTADOS

Utilizamos validaciones cruzadas de 5 veces para nuestros experimentos para evaluar la capacidad de generalizar los modelos de predicción y evitar el sobreajuste [18]. La validación cruzada se encarga de dividir la base de datos en subconjuntos que no comparten elementos y que, dependiendo del número de subconjuntos, son el número de experimentos que se realizarán. Siempre tomamos un subconjunto como conjunto de prueba y el resto como conjuntos de entrenamiento.

En la etapa de prueba, evaluamos el modelo utilizando dos métricas clave: precisión y función de pérdida. La precisión mide la proporción de predicciones correctas con respecto al número total de predicciones, lo que indica una tasa de éxito más alta con un valor más significativo. Por otro lado, la función de pérdida evalúa la representación del conjunto de datos del modelo. Un valor de pérdida más bajo indica una representación más precisa de los datos.

La Tabla 3 presenta los resultados de la validación cruzada de los mejores modelos en la etapa de entrenamiento, abarcando videos originales (V1), videos con relleno (V2) y videos con relleno y ruido (V3).

Tabla 3. Precisión de los mejores modelos en la etapa de entrenamiento a partir de una validación cruzada de 5 veces

Base de datos	V1	V2	V3
Fold_1	0.96	0.88	0.99
Fold_2	0.88	0.96	1.00
Fold_3	0.96	0.92	1.00
Fold_4	0.96	0.96	0.99
Fold_5	0.96	0.92	0.97
Promedio	0.94	0.92	0.99

Los videos originales arrojaron puntuaciones de precisión superiores al 90%, pero los valores de pérdida en la Tabla 4 sugieren un aprendizaje subóptimo.

El conjunto de vídeos acolchados logró una precisión promedio ligeramente inferior del 92 %, pero mostró valores de pérdida más bajos de 0,27, lo que indica un mejor aprendizaje. Por último, si bien mantuvieron altas tasas de precisión similares a las pruebas anteriores, los videos con relleno y ruido demostraron un aprendizaje superior basado en su valor de función de pérdida promedio más bajo de 0,06.

Para probar el sistema se incluyeron 14 videos de cada categoría sin modificaciones. Estos videos se separaron en las mismas categorías de no problema y problema y se usaron para comparar con las predicciones del sistema. Utilizamos cuatro métricas de evaluación para evaluar el desempeño de la clasificación: Accuracy, Recall, Precision y F1 score.

Estas métricas se calcularon utilizando la biblioteca Scikit-learn⁵, que es una herramienta para algoritmos de aprendizaje automático que ayuda a evaluar el modelo de red neuronal.

Tabla 4. La función de pérdida resulta de los mejores modelos en la etapa de entrenamiento de un quinto.

Base de datos	V1	V2	V3
Fold_1	0.24	0.32	0.04
Fold_2	0.35	0.29	0.01
Fold_3	0.27	0.31	0.03
Fold_4	0.20	0.14	0.12
Fold_5	0.38	0.29	0.10
Promedio	0.28	0.27	0.06

4. DISCUSIÓN

Podemos separar el comportamiento de cada modelo entrenado con diferentes bases de datos analizando sus resultados. El modelo entrenado con la base de datos V1 logró una recuperación del 93 % y una precisión del 91 % (Tabla V). Sin embargo, exhibió la mayor puntuación de la función de pérdida de 0,28 (Tabla IV). Esta discrepancia puede atribuirse al tamaño del video, como se evidencia en los resultados presentados en la Tabla VI, donde todos los valores fueron más bajos que el conjunto de datos de prueba sin relleno. En el modelo entrenado con la base de datos V2, las cosas resultan diferentes. La precisión y la exactitud estaban en su nivel más bajo, con 80% y 84%, respectivamente, como se muestra en la Tabla V. Ocurre el mismo comportamiento, pero a la inversa. El modelo V2 fue mejor con un conjunto de datos de prueba acolchado ya que fue entrenado con videos acolchados. Si observamos la Tabla IV, podemos ver que tuvo una mejor puntuación de función de pérdida de 0,27. Esto se puede percibir con una puntuación de recuerdo del 96%. Con este modelo estamos seguros de que detectará casos positivos con un 96% de éxito con vídeos con o sin relleno. Vemos los mejores resultados para el modelo entrenado con la base de datos V3. La precisión y la recuperación fueron mejores con 94% y 100%, respectivamente, en el conjunto de datos de prueba sin relleno. Una puntuación F1 del 94 % pero una recuperación del 100 % significa que este modelo, en algunos casos, predecirá positivo cuando un paciente no tenga el síntoma del signo de Gowers, pero en todos los casos, el modelo predecirá correctamente cuando un paciente de hecho presenta el síntoma del signo de Gowers. En el conjunto de datos con relleno, vemos un modelo más generalizado que reduce la puntuación de recuperación, pero obtiene mejores resultados en las otras métricas.

5. CONCLUSIONES Y TRABAJO FUTURO

La maniobra del signo de Gowers es un síntoma que puede detectarse mediante inspección visual. Sin embargo, muchos niños no acuden periódicamente al médico y no reciben un diagnóstico. Este sistema debería ayudar al personal médico a supervisar continuamente a los niños, ya sea en escuelas, guarderías, salas médicas o en cualquier lugar, para detectar la presencia de este movimiento. Este sistema podría identificar si existe alguna anomalía o problema, avisando a los padres y tratando el problema a una edad temprana, aumentando así la esperanza de vida de los pacientes.

Como parte del trabajo futuro, pretendemos realizar pruebas con varios modelos para evaluar el rendimiento del sistema en diferentes escenarios. Una limitación notable a la que nos enfrentamos fue la falta de una base de datos completa, lo que nos presentó la oportunidad de crear una nueva. Al hacerlo, nuestro objetivo es estimular el interés en recopilar videos que muestren la maniobra del Signo de Gowers, aumentando así los datos para futuros estudios e investigaciones.

Aunque los resultados obtenidos fueron relativamente altos, con una precisión de casi 1,00, es importante señalar que estos resultados se lograron con una base de datos pequeña. En consecuencia, existe una mayor probabilidad de sesgo en el sistema debido a la limitación de datos. A medida que continuamos recopilando más datos, anticipamos realizar pruebas adicionales para refinar y optimizar el sistema para su implementación práctica.

REFERENCIAS

- [1] Centers for Disease Control and Prevention, “Cdc’s developmental milestones,” 07 2023. [Online]. Available: <https://www.cdc.gov/ncbddd/actearly/milestones/index.html>
- [2] W. R. Gowers, *A manual of diseases of the nervous system*, 2nd ed. 1012 Walnut Street, Philadelphia: P. Blakiston, Son & Co., 1895. [Online]. Available: <http://resource.nlm.nih.gov/100954844>
- [3] R. F. Chang and S. J. Mubarak, “Pathomechanics of gowers’ sign: A video analysis of a spectrum of gowers’ maneuvers,” *Clinical Orthopaedics and Related Research*, vol. 470, no. 7, pp. 1987–1991, 2012. [Online]. Available: <https://doi.org/10.1007/s11999-011-2210-6>
- [4] J. Fokkema, S. Lopez-Hernandez, and L. Lopez-Hernandez, “Impacto de las organizaciones de padres en la investigación de la distrofia muscular de duchenne: el activismo materno como motor de cambio,” *Investigación en Discapacidad*, vol. 2, no. 3, pp. 135–140, 2013.
- [5] E. Landfeldt, R. Thompson, T. Sejersen, H. J. McMillan, J. Kirschner, and H. Lochmuller, “Life expectancy at birth in duchenne muscular dystrophy: a systematic review and meta-analysis,” *European Journal of Epidemiology*, vol. 35, no. 7, pp. 643–653, 2020. [Online]. Available: <https://doi.org/10.1007/s10654-020-00613-8>
- [6] J. Broomfield, M. Hill, M. Guglieri, M. Crowther, and K. Abrams, “Life expectancy in duchenne muscular dystrophy: Reproduced individual patient data metaanalysis.” *Neurology*, vol. 97, pp. e2304–e2314, Dec 2021.
- [7] N. Vázquez Cárdenas, F. Ibarra Hernández, L. Lopez Hernández, R. Escobar Cedillo, L. Ruano Calderón, B. Gómez Díaz, N. García Calderón, M. Carriedo Davila, L. Rojas Hurtado, E. Luna Padron, and R. Coral Vazquez, “Diagnóstico y tratamiento con esteroides de pacientes con distrofia muscular de duchenne: experiencia y recomendaciones para México,” *Revista de Neurología*, vol. 57, no. 10, p. 455, 2013.
- [8] L. Edwards and M. Phillips, “Neuromuscular conditions for physicians - what you need to know.” *Clinical medicine (London, England)*, vol. 16, pp. 259–61, Jun 2016.
- [9] H. J. A. van Ruiten, V. Straub, K. Bushby, and M. Guglieri, “Improving recognition of duchenne muscular dystrophy: a retrospective case note review,” *Archives of Disease in Childhood*, vol. 99, no. 12, pp. 1074–1077, 2014. [Online]. Available: <https://adc.bmj.com/content/99/12/1074>
- [10] S. H. Wong, B. J. McClaren, A. D. Archibald, A. Weeks, T. Langmaid, M. M. Ryan, A. Kornberg, and S. A. Metcalfe, “A mixed methods study of age at diagnosis and diagnostic odyssey for duchenne muscular dystrophy,” *European Journal of Human Genetics*, vol. 23, no. 10, pp. 1294–1300, 2015. [Online]. Available: <https://doi.org/10.1038/ejhg.2014.301>

- [11] J. Mah, “Current and emerging treatment strategies for duchenne muscular dystrophy,” *Neuropsychiatric Disease and Treatment*, vol. Volume 12, pp. 1795–1807, 07 2016.
- [12] F. Chollet et al., “Keras,” <https://keras.io>, 2012.
- [13] Y. Tang and C. Eliasmith, “Deep networks for robust visual recognition,” in *Proceedings of the 27th International Conference on International Conference on Machine Learning*, 08 2010, pp. 1055–1062.
- [14] J. Sietsma and R. J. Dow, “Creating artificial neural networks that generalize,” *Neural Networks*, vol. 4, no. 1, pp. 67–79, 1991. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/0893608091900332>
- [15] P. Ferlet, “Training a neural network with an image sequence - example with a video as input,” 2021.
- [16] “What are Recurrent Neural Networks? —IBM.” [Online]. Available: <https://www.ibm.com/topics/recurrent-neural-networks>
- [17] P. Ferlet, “How to work with time distributed data in a neural network,” *Medium*, Dec. 2021. [Online]. Available: <https://medium.com/smileinnovation/how-to-work-with-time-distributed-data-in-a-neural-network-b8b39a>
- [18] D. Berrar, “Cross-validation,” in *Reference Module in Life Sciences*, Jan. 2018.

Correo de Autor de Correspondencia: veronicaquintero@itmexicali.edu.mx