



Dyslexia recognition by handwriting using Convolutional Neural Networks

Carlos Enmanuel Espinoza-Vicuña, Egresado en Ciencia de la Computación¹, Yuri Nuñez-Medrano MSc. en Ingeniería de Sistemas²

^{1,2}Universidad Nacional de Ingeniería, Perú, ¹cespinozav@uni.pe, ²ynunezm@uni.edu.pe

Abstract— This project focuses on using technological tools to describe and classify children's handwriting behaviors. This in order to help a proper diagnosis of dyslexia. It was necessary to collect all the necessary information on Developmental Dyslexia. Thus, studying the origin, characteristics, diagnosis, treatments, etc. There are several tests to carry out a diagnosis. These are focused on the study of the phonetic behavior of the voice during a reading. In addition, reader-reader tests, among others. Given this, it has been decided to develop a mobile application, which performs reading-writing tests in participants with and without dyslexia. Thus, finding a large number of patterns that can be studied, mainly related to Dysgraphia, Dysortography and Dyscalculia. After collecting the images from the tests carried out, the second part is to find an artificial intelligence model that allows them to be classified. 2 models were used: convolutional model 1 and the Unet model. These models gave promising results. Finally, the need to continue collecting more images of reading-writing tests in patients with dyslexia was demonstrated.

Keywords— Dyslexia, Literacy tests, Dysgraphia, Dyssortography, Dyscalculia, Characteristics.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Reconocimiento de Dislexia mediante la escritura a mano usando Redes Neuronales Convolucionales

Carlos Enmanuel Espinoza-Vicuña, Pregrado en Ciencia de la Computación¹, Yuri Nuñez-Medrano MSc. en Ingeniería de Sistemas²

^{1,2}Universidad Nacional de Ingeniería, Perú, ¹cespinozav@uni.pe, ²ynunezm@uni.edu.pe

Resumen— Este proyecto se enfoca en utilizar herramientas tecnológicas para describir y clasificar comportamientos en la escritura a mano de niños. Esto con la finalidad de ayudar a un diagnóstico adecuado de dislexia. Fue necesario recabar toda la información necesaria sobre la Dislexia de Desarrollo. Estudiando así el origen, características, diagnóstico, tratamientos, etc. Existen varias pruebas para llevar a cabo un diagnóstico. Estas, están centradas en el estudio del comportamiento fonético de la voz durante una lectura. Además, de pruebas de lecto-lectora, entre otros. Visto esto, se ha optado por desarrollar un aplicativo móvil, que realiza pruebas de lecto-escritura en participantes con y sin dislexia. Encontrando así, una gran cantidad de patrones que puedan ser estudiados, relacionados principalmente a Disgrafía, Disortografía y Discalculia. Luego de recopilar las imágenes de las pruebas realizadas, la segunda parte es encontrar un modelo de inteligencia artificial que permita clasificarlas. Se usaron 2 modelos: modelo convolucional 1 y el modelo Unet. Estos modelos dieron resultados prometedores. Finalmente, se observó la necesidad de seguir recopilando más imágenes de las pruebas de lecto-escritura en pacientes con dislexia.

Keywords— Dislexia, Pruebas de lecto-escritura, Disgrafía, Disortografía, Discalculia, Características.

I. INTRODUCCIÓN

La dislexia es un trastorno de aprendizaje y afecta zonas del cerebro que procesan el lenguaje. Según la Asociación Internacional de Dislexia: “La dislexia es una discapacidad específica del aprendizaje que es de origen neurobiológico. Se caracteriza por dificultades con el reconocimiento preciso y fluido de las palabras; y por una mala ortografía y decodificación.” [1]. Uno de cada diez personas padece de este trastorno, lo que significa que 700 millones de niños y adultos en todo el mundo [2]. La característica principal de la dislexia es un problema con la decodificación de palabras, lo que a su vez afecta el rendimiento ortográfico y el desarrollo de la fluidez en la lectura [3]. La dislexia es persistente a lo largo de la vida y los resultados en los adultos son variables

A. Descripción del Problema

La dislexia, generalmente se relaciona a problemas de origen neurobiológico en la precisión y forma de lectura, pseudo-palabras únicas o texto; o de ortografía escrita. Sin embargo, investigaciones anteriores se han centrado más en la lectura que en los problemas de ortografía que presenta la dislexia [4]. Actualmente, la dislexia no es potencialmente mortal, pero involucran problemas de aprendizaje a una edad temprana que pueden afectar el desarrollo cognitivo y emocional de un niño. Las causas de la dislexia aún se

desconocen, aunque existen muchas teorías, algunas más populares que otras entre los científicos [5]. Según modelos cognitivos del desarrollo de la escritura dadas por Graham y Hayes [6]. Los pacientes con dislexia, especialmente niños, a menudo presentan dificultades para escribir. Esto, debido a que la escritura está ligada a varios procesos cognitivos, principalmente con la lectura. En un claro ejemplo: Al escribir un libro, los escritores a menudo necesitan leer varias fuentes antes de escribir su propio texto y también necesitan leer y releer su propia escritura para revisar problemas en el texto, como errores de ortografía, errores gramaticales y desorganización. La presencia de dificultades lectoras, especialmente en las primeras etapas de vida, complica la realización de muchas tareas relacionadas a estos procesos cognitivos. Estudios anteriores, encontraron que, al aprender a escribir, los niños poseen ciertos patrones significativos en el comportamiento de su escritura, desde la ortografía hasta en la composición de esta [4]. Las dificultades en la escritura se manifiestan en la mala ortografía, mala legibilidad, falta de vocabulario diverso, desarrollo deficiente de ideas y/o falta de organización [6]. Aunque la dislexia no tiene cura, una intervención temprana ayuda a conseguir grandes avances en el aprendizaje. Lastimosamente, muchas veces, la dislexia no se diagnostica durante años, incluso hasta llegar a la madurez humana.

II. OBJETIVOS

- Desarrollo de Software de un aplicativo móvil que realice pruebas de lecto-escritura, con la finalidad de describir comportamientos de escritura a mano. Estos comportamientos deben estar relacionados a la Disgrafía, Disortografía o Discalculia.
- Crear una base de datos, recopilando imágenes de las pruebas de lecto-escritura.
- Usar técnicas de limpieza de imágenes y data augmentation.
- Comparación de diferentes herramientas y modelos de inteligencia artificial para detectar y clasificar formas de escritura relacionadas a la dislexia.

III. ESTADO DEL ARTE

A. Descripción de la Dislexia

Se caracterizan por su deficiencia en las habilidades de lecto-escritura. Ello repercute en la habilidad de comprensión lectora, leer en voz alta, reconocimiento de palabras, deletrear

con capacidad de escribir correctamente y la ortografía [7]. Samuel Orton, uno de los pioneros en estudiar la dislexia. Encontró disfunciones en el cerebro como la especificidad de los hemisferios y acerca de niveles separados de funciones cerebrales visuales. Relacionándolo con el déficit visual. Así, los lectores disléxicos muestran una dificultad significativa para diferenciar las letras que son horizontal o verticalmente simétricas entre sí o giradas. Además, tiende a confundir las palabras palíndromas y leer parcialmente de derecha a izquierda. Además, estos estudiantes demuestran una capacidad notable para leer y escribir.

La dislexia, va de la mano con problemas de escritura escolar, tales como: Disgrafía, Disortografía, Discalculia, TDA-H. Cabe resaltar, que los rasgos en el comportamiento de la escritura obedecen a lo señalado por la OMS en [7]:

- **Disgrafía:** Esta relacionado con la dificultad de formar las letras. Ejercer la presión apropiada sobre el papel con la herramienta usada para escribir. Espaciar correctamente las letras en la página. Escribir en línea recta. Hacer las letras del tamaño correcto. Sostener el papel con una mano mientras escribe con la otra. Sostener y controlar un lápiz u otra herramienta para escribir. Mantener la postura y posición correcta del brazo para escribir.
- **Disortografía:** Es una discapacidad de aprendizaje, con estudio relativamente nuevo. Cuyos síntomas son los errores fonológicos, como omisiones, inversión de letras (pla / pal), sustitución de letras que son similares a nivel visual (grafemas) (b / d, p / q) o que tienen un sonido similar (fonemas) (f / v, s / z). Los errores no fonológicos, por falta de respeto a los errores gramaticales, errores en la conjugación de los verbos y en el uso de la puntuación. Además, se consideran los errores de sintaxis.
- **Discalculia:** Es la dificultad que un niño tiene al comprender, aprender y realizar operaciones matemáticas y numéricas. Entre los síntomas tenemos la dificultad para reconocer números, lucha por conectar los símbolos numéricos con sus palabras correspondientes, dificultad para reconocer patrones y poner las cosas en orden, perder la pista al contar, necesidad de usar ayudas visuales, como los dedos, para ayudar a contar, entre otros [8].

B. Investigaciones Relacionadas al Reconocimiento de Dislexia

Actualmente existen muchas investigaciones relacionadas al estudio del diagnóstico de dislexia empleando Inteligencia Artificial. Estos estudios están enfocados al análisis de comportamientos de señales electroencefalográficos (EEG) [9] [10]. Basado en el manejo de componentes de Análisis de Espectro Singular (SSA), extrayendo las características necesarias. Existen también investigaciones basadas en el estudio del movimiento de los ojos, tales como las investigaciones hechas en Change Dyslexia [11]. En el 2002, se empleó un estudio similar que consiste en rastrear movimientos oculares [12] y el estudio fue hecho por la Universidad de Jyväskylä, Finlandia. Esto debido a que “Las personas con

dislexia muestran más fijaciones, movimientos sacádicos más cortos y, en general, un movimiento ocular más irregular” [13]. Las investigaciones relacionadas directamente con este estudio son “Towards Detecting Dyslexia in Children’s Handwriting Using Neural Networks” y “Automated Detection of Dyslexia Symptom Based on Handwriting Image for Primary School Children”. El primer estudio tiene el objetivo de hallar un método basado en el análisis de escritura a mano de niños con dislexia. Esto con la finalidad de hacer más eficiente el diagnóstico de Dislexia en comparación a los que ya existen [14]. Primeramente, se armó una base de datos, recopilando 50 muestras de estudiantes con dislexia y 100 muestras de estudiantes sin dislexia. Luego, en el preprocesamiento, se dividieron las imágenes en segmentos de líneas usando la técnica Arvanitopoulos y Susstrunk’s seam carving [15] Se usó una red neuronal, con 5 capas, con la siguiente arquitectura: 3 capas max-pooling (MP), 2 capas full-connected (FC) y una capa de dropout. Probando con varios valores de batch sizes (1, 4, 16, 32) y cantidad de patches por línea (5, 10, 25, 50). Inicialmente, se obtuvo un accuracy promedio de 55.7 ± 1.4 %, generando overfitting. Para lidiar con ello, hace falta recopilar más datos y mejorar la red neuronal. Para el segundo caso, el estudio consiste en el reconocimiento de patrones de escritura, extrayendo características de caracteres escritos por estudiantes. Con ello, se obtiene un accuracy de 73.33 %. La red neuronal es utilizada para obtener niveles de riesgo de tener dislexia (bajo o alto riesgo). Los manuscritos obtenidos se recopilaron en conjunto con la Asociación de Dislexia de Malasia. Entre los comportamientos estudiados, asociados a la dislexia, tenemos a la disgrafía y discalculia. Se utilizaron diferentes herramientas para la extracción de características en imágenes de este tipo como el llamado región FilteredTextMask.

C. Redes Neuronales Convolucionales

Una red neuronal convolucional está diseñada para procesar datos y conformada básicamente por capas convolucionales con una capa final totalmente conectada y una capa de predicción de salida, como se muestra en la figura 3.1. La capa convolucional ReLU y la capa de pooling son las más utilizadas [16].

El objetivo de las capas convolucionales es determinar las conexiones locales de entidades de las capas anteriores y mapear su información a mapas de entidades particulares [16]. Para una entrada I con filtro F ($F \in R^{2a_1+2a_2}$) a convolución se da de la forma:

$$(I * F) = \sum_{k=-a_1}^{k=a_1} \sum_{l=-a_1}^{l=a_1} 2F_{k,l} I_{n-k,m-l} \quad [16]$$

La capa max-pooling combina características similares transmitidas desde la capa anterior. Además, realizan la operación de muestreo descendente calculando el valor máximo del campo en el mapa de características superpuesto con el kernel. En resumen, hacer un sub-sampling de max-pooling

encuentra el valor máximo entre una ventana de muestra y pasa este valor como resumen de características sobre esa área. Como resultado, el tamaño de los datos se reduce por un factor igual al tamaño de la ventana de muestra sobre la cual se opera. La estructura CNN, que es desde la capa Full connected (fc) hasta la capa de clasificación, es en general similar a la red neuronal perceptrónica de múltiples capas (MLP). La tarea de las capas fc es la misma que las capas ocultas en el MLP. Una o más capas fc pueden estar en una estructura CNN. La capa fc conecta cada neurona en la siguiente capa con cada neurona en la capa anterior.




Figura 3.1: Arquitectura de una Red Neuronal Convolutiva [16].

La función de activación RELU ($g(z) = \max(0, z)$), conocida también como función de activación de no linealidad, se aplica a los mapas de características creados con las capas convolucionales. La función Softmax generalmente se utiliza en CNN, para hacer coincidir los valores no normalizados de la capa anterior con una distribución de posibilidades sobre los puntajes de clase pronosticados.

D. U-Net.

Es una arquitectura de segmentación semántica, la que consiste de un camino de contracción y un camino expansivo, el camino de contracción sigue la típica arquitectura de una red convolutiva, como en la figura 3.2.




Figura 3.2: Arquitectura U-net. Los cuadros azules corresponden a un mapa de características multicanal. El número de canales se indica en la parte superior de los cuadros. Los cuadros blancos representan mapas de características copiados. Las flechas indican las diferentes operaciones [35].

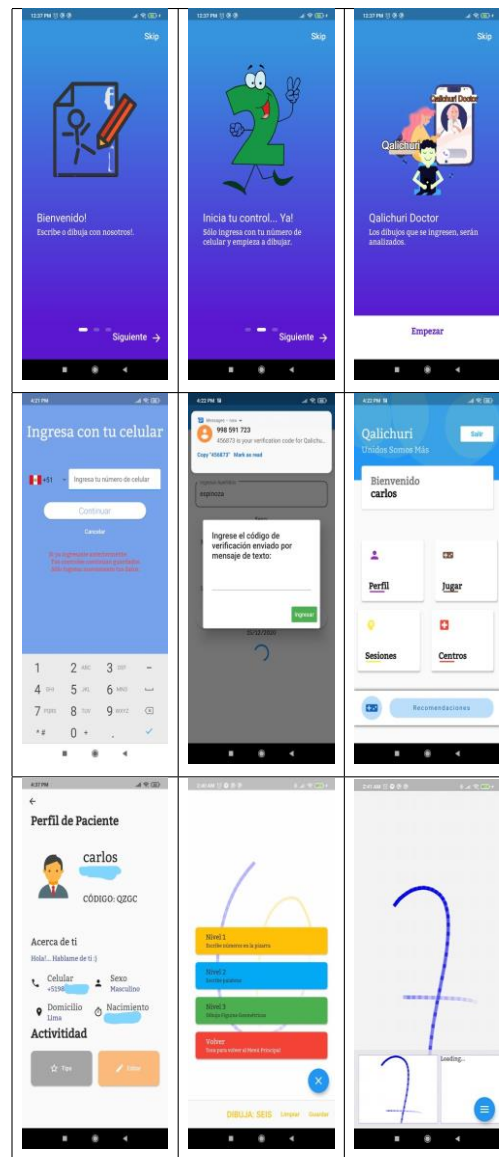


Figura 3.3: Aplicativo Móvil.

IV. METODOLOGÍA DE INVESTIGACIÓN

A. Desarrollo de Software

Tras formular los requerimientos con toda la información recopilada acerca de la Dislexia. Se optó por desarrollar un aplicativo móvil diseñado para describir y recopilar comportamientos de lecto-escritura. Este comportamiento está compuesto por trazos con características relacionadas con la Discalculia, Disortografía y Disgrafía. Entre ellas tenemos el color empezando con un trazo azul (Color ARGB(255, 0, 0, 255)), le sigue el trazo de color ambar (Color ARGB(255,255,191,0)) y finaliza con el trazo de color rojo (Color ARGB(255,255,0,0)). El degradado, el color se degrada un 2.5% adicional con respecto al punto anterior. El grosor, se suaviza de color en color mientras se sigue el trazo. Una vez terminado el dibujo, el aplicativo realiza un renderizado de ello.

Luego, es guardado en una imagen en formato .png. Finalmente, esta imagen se almacena en la base de datos en la nube. En la Figura 3.4, se muestran diagrama de Caso de Uso para el aplicativo móvil. Además, en la Figura 3.5, se muestra un Diagrama de Clases, que sirve para visualizar las relaciones entre las clases que hay en el aplicativo móvil.




Figura 3.4: Diagrama de Caso del aplicativo móvil.

B. Análisis de Datos Obtenidos

Se obtuvieron más de 790 imágenes interesantes y con gran potencial a ser analizados. Estas imágenes poseen 26 clasificaciones. Los símbolos usados van del 0 al 9 y cada uno con tres estados o comportamientos en la escritura. Excepto el 0 y 8 que sólo posee un estado o clasificación. A continuación, se muestran algunos datos respecto a los pacientes y las sesiones realizadas, vista en la Tabla 3.1. Se observaron generalmente trazos rojos más largos y poco pronunciamiento de degradado en los escritos relacionados con dislexia. Además, signos de poca velocidad y pequeños puntos resaltantes en los trazos, signo de que los participantes se detienen durante la escritura. Finalmente, inclinaciones muy pronunciadas que pueden ser signo de disgrafía. En la tabla 3.2. Se muestran ejemplos de las pruebas de lecto-escritura con trazos relacionados a diferentes comportamientos. Los participantes, cuyo estado de dislexia está etiquetada como 0, no presentan signos relacionados a este trastorno. El estado 1 presenta un repetitivo comportamiento de lecto-escritura caracterizado por un patrón de escritura con trayectoria inversa. Este comportamiento disléxico, es muy variado, dado que pueden empezar a escribir desde cualquier punto del símbolo escrito y seguir una trayectoria inversa. Para los participantes que poseen un estado de dislexia 2, presentan una escritura inversa en forma, con variadas trayectorias o recorrido. Este estado de escritura se presenta pocas veces en los test realizados.




Figura 3.5: Diagrama de Clases del aplicativo móvil.

C. Preprocesamiento de Imágenes

Es probable encontrar algunas manchas fuera y sobre las imágenes a consecuencia de errores al usar el aplicativo. Para ello, se usa el algoritmo conocido como maximally stable extremal regions (MSER), para detectar y filtrar esas imperfecciones. La idea se basa en discriminar regiones que pertenezcan a un conjunto más grande de regiones a través de una amplia gama de umbrales y el uso de detector de regiones. La siguiente etapa consiste en aplicar data augmentation. Se usan herramientas que realizan transformaciones afines a las imágenes obtenidas. Permitiendo, realizar rotaciones, escalar y cortes transversales. Al aplicar estos métodos sobre las imágenes que se recopilieron, se obtuvieron al menos 15600 imágenes, distribuidas para entrenamiento, validación y testeo.

TABLA 3.1: DESCRIPCIÓN DE LOS TESTS DE LECTO-ESCRITURA

Código	Sessions	Cantidad de Imágenes	Diagnóstico	Estado de Dislexia
P RFSN	8	139	Positivo	2
P XUVC	4	99	Positivo	1
P HOMD	4	50	Negativo	0
P FU29	4	105	Negativo	0
P D576	2	50	Negativo	0
P R79P	2	20	Negativo	0
P BCFC	2	28	Positivo	1
P OEBB	6	165	Positivo	2
P ANRF	6	90	Positivo	1
P QSX7	4	32	Positivo	1
P JWPF	4	14	Negativo	0

TABLA 3.2: SÍMBOLOS ESCRITOS SEGÚN ESTADOS DE DISLEXIA

Estado 0				
Estado 1				
Estado 2				

A continuación, se muestran las imágenes resultantes de las técnicas de data augmentation empleadas. Llegando a obtener alrededor de 15600 para el estudio. Cabe resaltar que al aplicar estas técnicas se mantuvieron los patrones característicos de cada estado o clasificación.

TABLA 3.3: RESULTADOS DE LAS TÉCNICAS DE DATA AUGMENTATION.

Imagen Original	Rotación	Deslizamiento	Voltear	Degradaciones

D. Redes Neuronales Convolucionales

Para detectar o clasificar comportamientos de los participantes en la escritura a mano, es necesario probar con distintas redes convolucionales.

- El Modelo Convolutivo 1 posee diferentes etapas. La primera es la capa de entrada, la dimensión de entrada depende de las dimensiones de las imágenes de entrada. La segunda, se realiza dos convoluciones con 88 kernels, de dimensión 3x3. Además de una función de activación relu. Se agrega una capa Add() con una lista de las dos convoluciones anteriores. Esto, toma como entrada esta lista, todos de la misma forma, y devuelve un solo tensor

(también de la misma forma). Luego un sub-sampling maxpooling con kernel de 3x3 y un dropout. La tercera y cuarta etapa son similares a la segunda. Al final, quedan una matriz resultante de dimensión 13x13. En la capa Full-Connection, se transforma un vector tridimensional en un vector de tamaño 14872. Luego este vector pasa por tres capas densas. La salida de la capa Densa se ve afectada por el número de neuronas (unidades) especificadas en la capa Densa. Por ejemplo, para la primera capa posee una salida de 256, la segunda de 128 quedando una salida con dos unidades.

- El Modelo Unet como en la figura 3.6, se divide en bloques con sus respectivas capas convolucionales. La arquitectura Unet, consta de una ruta de contracción y una ruta expansiva. La ruta de contracción, consta del bloque (2 conv1, pool1, 2 conv2, pool2, 2 conv3, pool3, 2 conv4, pool4 y 2 conv5) sigue la arquitectura típica de una red convolutiva. Consiste en la aplicación repetida de dos convoluciones de 3x3, usando funciones de activación Relu y una operación max-pooling 2x2 cada dos pasos de convolución. La ruta expansiva consta de un UpSampling, con kernels de 2x2, una concatenación entre convoluciones de forma simétrica y dos convoluciones de 3x3, cada una seguida de un ReLU. En la capa final, se utiliza una convolución 1x1 para asignar cada vector de características de 64 componentes al número deseado de clases. En total, la red tiene 4 bloques convolucionales para cada ruta. La idea es complementar una red habitual con capas sucesivas, donde los operadores de max-pooling son reemplazados por operadores de Upsampling. Por lo tanto, estas capas aumentan la resolución de la salida [35].


IV. DISCUSIÓN DE RESULTADOS

A. Modelo Convolutivo 1.

En la Tabla 4.1, se observan gráficas con los comportamientos de loss para el Modelo 1, usando como entrada imágenes a escala de grises y color con canales RGBA. En ambos casos, el comportamiento de caída en loss para datos de entrenamiento es más pronunciado que para los datos de validación. Para imágenes a escala de grises, se observa que los en el entrenamiento decrece de forma rápida hasta 0.2 luego de 16 épocas, y continúa decreciendo. Mientras que, para los datos de validación, decrece de forma más suave llegado a 0.2 luego de 17 épocas y se mantiene cerca a ese valor.

Para imágenes a color usando canales RGBA, se observa que los en el entrenamiento decrece de forma rápida hasta 0.1 luego de 9 épocas, y continúa decreciendo. De forma similar, para los datos de validación, decrece de la misma forma llegado a 0.08 luego de 70 épocas y se mantiene cerca a ese valor.


TABLA 4.1: GRAFICAS DE LOSS PARA EL MODELO 1



En la Tabla 4.2, se observan gráficas con los comportamientos de accuracy para el Modelo 1, usando como entrada imágenes a escala de grises y color con canales RGBA.

En ambos casos, el comportamiento del accuracy para datos de entrenamiento es más pronunciada que para los datos de validación. Para imágenes a escala de grises, se observa que el accuracy en el entrenamiento crece de forma rápida hasta 0.98 luego de 40 épocas, y continúa creciendo. Mientras que, para los datos de validación, crece de forma más suave llegado a 0.95 luego de 104 épocas y se mantiene cerca a ese valor. Para imágenes a color usando canales RBGA, se observa que el accuracy en el entrenamiento crece de forma rápida hasta 0.99 luego de 36 épocas, y continúa creciendo. De forma similar, para los datos de validación, crece de la misma forma llegado a 0.98 luego de 50 épocas y se mantiene cerca a ese valor.

TABLA 4.2: GRAFICAS DE ACCURACY PARA EL MODELO 1




B. Modelo Convolutional Unet.

Para el modelo Unet, se tiene que el comportamiento de Loss en el entrenamiento y validación es similar usando tanto imágenes a escala de grises como a color. Para imágenes a escala de grises, se observa que los en el entrenamiento decrece de forma rápida hasta 0.05 luego de 8 épocas, y continúa decreciendo. Mientras que, para los datos de validación, decrece hasta 0.1 luego de 34 épocas y se mantiene cerca a ese valor. Para imágenes a color usando canales RBGA, se observa que los en el entrenamiento decrece de forma rápida hasta 0.001 luego de 7 épocas, y continúa decreciendo. Para los datos de

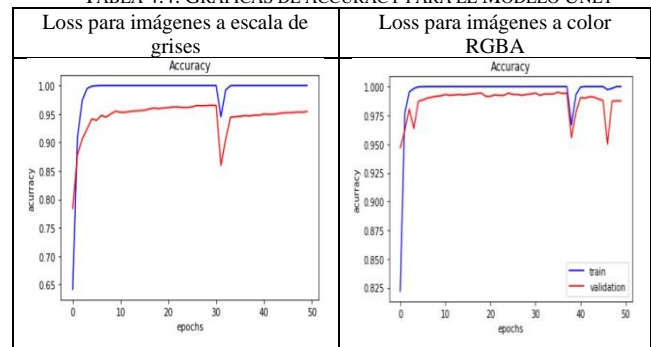
validación, decrece hasta 0.02 luego de 9 épocas y se mantiene cerca a ese valor.

TABLA 4.3: GRAFICAS DE PARA EL MODELO UNET



En la Tabla 4.4, se observa que el comportamiento del accuracy para Modelo Unet, usando como entrada imágenes a escala de grises y color. En ambos casos, el comportamiento del accuracy para datos de entrenamiento validación es similar. Para imágenes a escala de grises, se observa que el accuracy en el entrenamiento crece de forma rápida hasta 0.99 luego de 6 épocas, y continúa creciendo. Mientras que, para los datos de validación, crece de forma suave llegado a 0.95 luego de 10 épocas y se mantiene cerca a ese valor. Para imágenes a color usando canales RBGA, el comportamiento del accuracy es similar que cuando se entrena el modelo Unet usando imágenes a escala de grises. Así, este crece de forma rápida hasta 0.99 luego de 6 épocas, y continúa creciendo. De forma similar, para los datos de validación, crece de la misma forma llegado a 0.98 luego de 7 épocas y se mantiene cerca a ese valor. En ambas gráficas, existen ciertas disminuciones precipitadas en el accuracy.

TABLA 4.4: GRAFICAS DE ACCURACY PARA EL MODELO UNET



C. Resultados.

Los resultados observados del aplicativo móvil y los modelos de redes convolucionales fueron interesantes. En primer lugar, el aplicativo pasó por varias etapas de pruebas que permitieron cumplir su función principal de describir los comportamientos en la escritura a mano de los participantes. De las imágenes obtenidas, se clasificaron en 26 tipos con distintos patrones. Se descartaron imágenes cuyo patrón de escritura eran

pocos vistos. En segundo lugar, comparando los modelos entrenados, se obtuvo que el Modelo Convolutacional 1 tiene un comportamiento lento, con respecto al Modelo Unet. Se hicieron pruebas con imágenes a color y escala de grises, observando un mayor accuracy en el Modelo Unet y el Modelo Convolutacional 1. El comportamiento del accuracy y loss del Modelo Convolutacional 1 converge luego de 40 épocas, el accuracy para imágenes de escala de grises es 0.95 y para imágenes a color es 0.98. El Modelo Unet converge luego de 4 épocas, el entrenamiento se detiene luego de 50 El accuracy para imágenes de escala grises es 0.954 y para imágenes a color es 0.987.

TABLA 4.5 COMPARACIÓN DE MODELOS

Modelos	Modo de Imágenes	Accuracy
Modelo 1	Escala de Grises	0.95
	Color RGBA	0.98
Modelo Unet	Escala de Grises	0.954
	Color RGBA	0.987

CONCLUSIONES

Para el reconocimiento de patrones de escritura a mano en participantes con y sin dislexia, se obtuvieron los resultados esperados. Esto debido a que se cubrieron los requerimientos necesarios para el desarrollo del aplicativo móvil, pudiendo describir, almacenar y procesar patrones de escritura a mano. Cabe resaltar que es posible agregar más tipos de tests. En base a la metodología desarrollada, se ha observado que se tuvo similar experiencia que las investigaciones anteriores. Especialmente, al implementar diferentes métodos para el pre-procesamiento de imágenes. Los modelos convolucionales usados mostraron ser efectivos, mayores a 0.95 de accuracy. También, se experimentaron comportamientos de overfitting, Esto despierta la necesidad de seguir recopilando más patrones de escritura en pacientes con dislexia.

AGRADECIMIENTO

Se agradece a la Universidad Nacional de Ingeniería Perú UNI, especialmente a la Facultad de Ciencias y al Vicerrectorado de Investigación de la UNI.

REFERENCIAS

[1] International Dyslexia Association Oregon. 'About Dyslexia'. <https://or.dyslexiaida.org/spanish-grid/sobre-la-dislexia-about-dyslexia/>

[2] Dyslexia International in collaboration with the Center for Child and Family Policy at Duke University; "Dyslexia is Impact DYSLEXIA INTERNATIONAL: BETTER TRAINING, BETTER TEACHING". Dyslexia International Rue Washington 40, B-1050 Brussels. April 17, 2014.

[3] Margaret J. Snowling, "Early identification and interventions for dyslexia: a contemporary view". Published in final edited form as: J Res Spec Educ Needs. 2013 Jan 1; 13(1): 7–14. doi: 10.1111/j.1471-3802.2012.01262. x.

[4] Virginia W. Berninger, Kathleen H. Nielsen, Robert D. Abbott, Ellen Wijsman, Wendy Raskind;" Writing Problems in Developmental Dyslexia:

Under-Recognized and Under-Treated". Published in final edited form as: J Sch Psychol. 2008 Feb; 46(1): 1–21.

[5] Javier Gay'an Guardiola, "The evolution of research on dyslexia", Institute for Behavioral Genetics and Department of Psychology, University of Colorado, Boulder, CO, EEUU. 2021.

[6] Michael Hebert, Devin M. Kearns, Joanne Baker Hayes, Pamela Bazis, Samantha Coopera, "Why Children with Dyslexia Struggle With Writing and How to Help Them". Published online 2018 Oct 24. doi: 10.1044/2018 LSHSS-DYSLC-18-0024.

[7] Pedro García Parajuá, Mónica Magariños López para Organización Mundial de La Salud; Clasificación de los Trastornos Mentales y del Comportamiento CIE-10 CDI-10". Editorial Médica Panamericana. Pág 191-195. Mayo, 2000.

[8] Rae Jacobson, Child Mind Institute; "How to Spot Dyscalculia". Child Mind Institute. September 21, 2022.

[9] Andres OrtízEmail authorFrancisco J. Martínez-MurciaMarco A. FormosoJuan Luis LuqueAuxiliadora Sánchez; "Dyslexia Detection from EEG Signals Using SSA Component Correlation and Convolutional Neural Networks". November 04, 2020.

[10] Z. Rezvani, M. Zare, G. Zari'c, M. Bonte, J. Tijms, M.W. Van der Molen, G. ~ Fraga González; "Machine learning Classification of Dyslexic Children based on EEG Local Network Features". March 13, 2019.

[11] Luz Rello (Human-Computer Interaction Institute), Miguel Ballesteros (Natural Language Processing Group, Universitat Pompeu Fabra); "Detecting Readers with Dyslexia Using Machine Learning with Eye Tracking Measures". May 2015.

[12] De Luca, M., Borrelli, M., Judica, A., Spinelli, D., and Zoccolotti, P. Reading Words and Pseudowords: An Eye Movement Study of Developmental Dyslexia". March 2002.

[13] Peter Raatikainen, University of Jyväskylä, Department of Mathematical Information Technology; "Automatic detection of developmental dyslexia from eye movement data". December, 2021.

[14] Katie Spoon, David Crandall, Katie Siek, "Towards Detecting Dyslexia in Children's Handwriting Using Neural Networks". 2019.

[15] Arvanitopoulos, N. and Sstrunk, S; "Seam Carving for Text Line Extraction on Color and Grayscale Historical Manuscripts". September 2014.

[16] Fatih Demir Firat (University Department of Electrical and Electronic Engineering), Daban Abdullah, Abdulkadir Sengur Firat (University Department of Electrical and Electronic Engineering); "A New Deep CNN model for Environmental Sound Classification". 01 April, 2020.

[17] Shallu Rajesh Mehra, "Breast cancer histology images classification: Training from scratch or transfer learning?", The Korean Institute of Communications and Information Sciences (KICS). Publishing Services by Elsevier B.V. December, 2018

[18] Fuzhen Zhuang, Zhiyuan Qi, Keyu Duan, Dongbo Xi, Yongchun Zhu, Hengshu Zhu, Senior Member, IEEE, Hui Xiong, Fellow, IEEE, and Qing He. "A Comprehensive Survey on Transfer Learning". 23 June, 2020.

[19] Rohit Thakur, "Step by step VGG16 implementation in Keras for beginners". Towards Data Science url: <https://towardsdatascience.com/step-by-step-vgg16-implementation-in-keras-for-beginners-a833c686ae6c::text=VGG16>. June, 2020.

[20] Aakash Kaushik. "Understanding the VGG19 Architecture". Student at SRM Institute of Science and Technology. url: <https://iq.opengenus.org/vgg19-architecture/>. 2023.