

Propuesta para el reconocimiento facial como herramienta de apoyo en tratamientos psicológico.

Jesús Yael Vargas Valdez A., Dra. Doricela Gutiérrez Cruz B., Dr. Javier Romero Torres C., Dr. Israel Gutiérrez González D.

^a Centro Universitario UAEM Nezahualcóyotl, yaelyv@gmail.com, Nezahualcóyotl, Estado de México, Méx.

^b Centro Universitario UAEM Nezahualcóyotl, dgutierrezcr@uamex.mx, Nezahualcóyotl, Estado de México, Méx.

^c Centro Universitario UAEM Nezahualcóyotl, jromero@uamex.mx, Estado de México, Méx.

^d Centro Universitario UAEM Nezahualcóyotl, igutierrezg@uamex.mx, Estado de México, Méx.

Resumen

Derivado de la repercusión post pandemia por COVID-19 en el ámbito psicológico, algunas de estas intervenciones migraron a la modalidad en línea, a fin de seguir con el acompañamiento necesario, aplicaciones con inteligencia artificial tomaron importancia en esta área, tal es el caso del reconocimiento facial de expresiones en la mejora de los resultados de la psicoterapia.

En el presente trabajo se presenta una propuesta, empleando la metodología RAD (Desarrollo Rápido de Aplicaciones) para el diseño de la aplicación, centrándose en la participación del usuario y el uso de tecnologías como las redes neuronales convolucionales y el transfer learning con una red preentrenada (VGG16) para el reconocimiento facial.

Se obtuvo una tasa de precisión promedio del 80%, así como detalles sobre la sensibilidad y especificidad para diversas expresiones emocionales, destacando la importancia de la intervención humana para ajustar las clasificaciones de emociones, resaltando la necesidad de colaboración entre la tecnología y el psicoterapeuta.

Palabras clave: Expresiones fáciles, Psicoterapia, Reconocimiento Facial.

Abstract

This work addresses the impact of the COVID-19 pandemic on mental health and proposes the design of an application with facial recognition to support psychological treatments. The importance of adapting therapeutic interventions to current circumstances is highlighted, and it is noted that online interventions, supported by facial recognition, have gained relevance. The role of artificial intelligence, especially facial expression recognition, in improving psychotherapy outcomes is highlighted, also addressing ethical and privacy issues associated with facial recognition. Using the RAD (Rapid Application Development) methodology for the design of the application, focusing on user participation and the use of technologies such as convolutional neural networks and transfer learning with a pre-trained network (VGG16) for facial recognition. An average accuracy rate of 80% is obtained, and details on sensitivity and specificity for various emotional expressions are presented, highlighting the importance of human intervention to adjust emotion

classifications, highlighting the need for collaboration between technology and psychotherapist.

Keywords: Easy expressions, Psychotherapy, Facial Recognition.

1. INTRODUCCIÓN

La emergencia de la pandemia de la COVID-19 ha generado un impacto inmediato y significativo en el bienestar de la población mundial. Además, se ha observado una repercusión en la salud mental, provocada por diversos factores físicos y psicológicos. Este fenómeno afecta tanto a la población en general, que no presenta síntomas clínicos, como a aquellos que han contraído la enfermedad, así como a los profesionales de la salud y a los grupos más susceptibles, como los adultos mayores y aquellos que sufren trastornos o enfermedades mentales, modificando de manera significativa la vida cotidiana, con la instauración de medidas de confinamiento preventivo a nivel global, destacando la importancia de adaptar la atención de seguimiento a las circunstancias actuales.

Por lo anterior, las intervenciones terapéuticas en línea han ganado importancia, y la evidencia sugiere que se puede establecer una fuerte alianza terapéutica a través de sesiones en línea, a veces incluso más fuerte que las sesiones presenciales. Diversos estudios apoyan la noción de que la tele terapia no es inferior a la terapia presencial en términos de alianza terapéutica y resultado clínico [1]. Además del cambio hacia las modalidades en línea, el uso de herramientas de reconocimiento facial para el reconocimiento de emociones se ha convertido en una ayuda potencial en el seguimiento terapéutico. Las reacciones faciales juegan un papel importante en las interacciones sociales y pueden contribuir a las dificultades reportadas por pacientes con ciertos trastornos. Los estudios han demostrado que las intervenciones dirigidas al reconocimiento de emociones faciales pueden mejorar la capacidad de reconocimiento de emociones y tener un potencial clínico importante para las personas con afecciones del neurodesarrollo como el autismo [2].

En este sentido, el cambio hacia las intervenciones terapéuticas en línea a visualizado la importancia de adaptarse en la atención de las circunstancias, con el uso de herramientas de reconocimiento facial para la identificación de emociones presenta una vía potencial para mejorar este seguimiento terapéutico. A medida que el panorama de la atención médica continúa evolucionando en respuesta a la pandemia, es crucial priorizar el desarrollo y mantenimiento de relaciones terapéuticas efectivas, tanto en entornos tradicionales como digitales.

En el presente trabajo se plantea una propuesta para realizar el diseño de una aplicación con reconocimiento facial como herramienta de apoyo en tratamiento psicológicos, a través de la detección de expresiones faciales relevantes, emociones y comportamientos, con el fin de fortalecer la eficacia de las intervenciones terapéuticas.

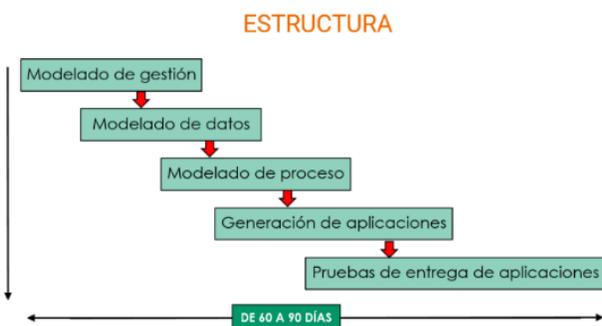
2. TRABAJOS RELACIONADOS

La tecnología de reconocimiento facial se ha propuesto como herramienta de apoyo en tratamientos psicológicos. La psicoterapia tradicional tiene limitaciones y la integración de la inteligencia artificial (IA) puede abordar estas deficiencias. Las tecnologías de inteligencia artificial, como el reconocimiento de expresiones faciales y los chatbots, pueden mejorar los resultados de la psicoterapia [3]. Sin embargo, el análisis del reconocimiento facial sin restricciones plantea cuestiones éticas y de privacidad. Estudios anteriores se han centrado en el reconocimiento facial restringido en entornos controlados, pero el rendimiento del reconocimiento se degrada cuando el entorno cambia o el sujeto muestra diferentes expresiones faciales [4] [5]. El reconocimiento de emociones a través de expresiones faciales es particularmente importante para la población de edad avanzada, ya que los cambios en la percepción y la cognición pueden afectar su capacidad para reconocer y expresar emociones [6]. Las herramientas tecnológicas, como la detección no invasiva de parámetros fisiológicos y el análisis de expresiones faciales, pueden mejorar el proceso de diagnóstico en psicología [7]. Estos trabajos relacionados proporcionan información sobre el potencial del reconocimiento facial como herramienta de apoyo en tratamientos psicológicos, destacando sus ventajas y limitaciones.

3. METODOLOGIA

La metodología RAD es un enfoque de desarrollo de sistemas que tiene como objetivo acelerar el proceso de diseño mediante el empleo de diseño de aplicaciones conjuntas, prototipado, tecnología CASE y generadores de aplicaciones. Se centra en las herramientas, las personas, la metodología y la gestión, y promueve una mejor comunicación, cooperación y compromiso entre el usuario y el diseñador. RAD generalmente consta de cuatro fases: planificación de requerimientos, diseño del usuario, construcción y corte, como se muestra en la figura 1, donde estos son desfasados. Se puede utilizar como una alternativa al ciclo de vida de desarrollo del sistema tradicional, permitiendo pasos iterativos o un diseño de sistema en evolución [8]. La metodología RAD es especialmente efectiva en proyectos donde los requisitos no están completamente definidos al inicio y pueden evolucionar con el tiempo [9].

Fig. 1. Diagrama del proceso RAD



Fuente: Estrada, G. (2017). Metodología RAD. [Diagrama]. Recuperado de

<https://ha2nv5020175.wordpress.com/2017/06/16/metodologia-rad/>

3.1 MODELADO DE GESTIÓN

Para capacitar y evaluar un sistema de reconocimiento facial como herramienta de apoyo en tratamientos psicológicos, se necesitan varios tipos de datos. Estos incluyen conjuntos de datos de expresión facial, que se pueden obtener a partir de conjuntos de datos disponibles públicamente, conjuntos de datos publicados de la literatura o recopilando sus propios datos [3]. Adicionalmente, se requieren modelos de entrenamiento para la capacidad de generalización de modelos, lo que puede implicar el uso de tecnologías de inteligencia artificial como reconocimiento de expresión facial y chatbots [10]. Es importante considerar las limitaciones de la tecnología, como la disponibilidad de conjuntos de datos de microexpresión y la necesidad de modelos de entrenamiento suficientes [11]. Además, la evaluación del sistema debe centrarse en la precisión de las capacidades de reconocimiento facial y su capacidad para apoyar a los médicos en el diagnóstico de síntomas a través de expresiones faciales [12]. Al considerar estos factores, el sistema de reconocimiento facial puede ser entrenado y evaluado de manera efectiva para su uso en tratamientos psicológicos.

3.2. MODELADO DE DATOS

El software tendrá que ser entrenado con diferente rostro con las variaciones de gestos, como se puede apreciar la figura 2, donde es el mismo hombre con diferentes facciones, accesorios, etc. Esto para poder identificarlo con diferentes características en el rostro, pero lo importante son todos los gestos que el individuo logre hacer.

Fig. 2. Ejemplo de 10 imágenes de un individuo de la base de datos Yale con diferente iluminación, expresión y postura



Fuente: Yale. (1997), Face Database. [Imagen]. Recuperado de <https://cvc.cs.yale.edu/cvc/projects/yalefaces/yalefaces.html>

3.2.1. Videos de sesiones terapéuticas

Si es posible y ético, grabar sesiones terapéuticas para obtener secuencias de expresiones faciales en un contexto natural. Anotar las emociones asociadas con cada momento del video para el entrenamiento y evaluación del modelo.

3.2.2. Datos Demográficos y Contextuales

Recopilar información demográfica relevante, como edad y género de los participantes, ya que estas variables pueden influir en la expresión emocional. Considerar el contexto de las sesiones terapéuticas, como el tipo de terapia, la duración de la sesión y el entorno.

3.3. MODELADO DE PROCESOS

3.3.1. Redimensionamiento de Imágenes

Ajustar todas las imágenes a un tamaño estándar para garantizar la consistencia en la entrada del modelo. Por ejemplo, puedes redimensionar todas las imágenes a 128x128 píxeles.

3.3.2. Normalización de Intensidad de Píxeles

Normalizar los valores de píxeles para que estén en una escala común (por ejemplo, de 0 a 1), esto va a hacer que el modelo converja más rápidamente durante el entrenamiento.

3.3.4. Extracción de Características

Considerar la posibilidad de utilizar técnicas de extracción de características para el reconocimiento de emociones, dentro de las cuales se puede mencionar: la detección de rostros y la extracción de características basada en la región, como el cálculo del área bucal y el método de Regiones Extremas Máximamente Estables (MSER), para extraer características relevantes en la detección de emociones [3]. Estas técnicas ayudan a representar y clasificar con precisión los datos, ya sea una imagen, actividad cerebral o expresión emocional. La principal utilidad de estas técnicas reside en su capacidad para capturar y representar de forma eficaz las características fundamentales asociadas con las emociones humanas. Al identificar y extraer estas características, los sistemas de reconocimiento de emociones pueden mejorar su capacidad para interpretar y comprender las señales emocionales de manera más precisa.

3.3.5. Balanceo de Clases

Verificar si las clases de emociones están balanceadas en tu conjunto de datos.

3.3.7. Codificación de Etiquetas

Convertir las etiquetas de emociones en formatos adecuados para el modelo, como codificación one-hot [14], cabe recalcar que de esta parte la librería que se utiliza ya lo hace por ti.

3.4. GENERACION DE LA APLICACION

Supongamos que se ha recopilado un conjunto de datos de imágenes faciales etiquetadas con diferentes emociones y que se está trabajando en un problema de clasificación de emociones. Aquí hay un ejemplo de cómo podrías seleccionar un modelo para abordar este problema:

3.4.1. Modelo de Red Neuronal Convolutiva (CNN)

Las CNN son ampliamente utilizadas para tareas de visión por computadora y son efectivas en la extracción de características espaciales en imágenes. Se puede utilizar una CNN para aprender patrones discriminativos de las expresiones faciales, es decir, ser más selectivo en lo que se quiere procesar. Aquí hay un ejemplo de cómo funcionaría utilizando lenguaje de programación Python y la librería Keras la cual está diseñada para realizar experimentos con redes neuronales ya que esta permite crear prototipos

rápidamente y de manera sencilla ya que está pensada para que su uso sea fácil de implementar, así como se muestra en la figura 3.

Fig. 3. Ejemplo del código para una red neuronal convolucional.

```
from keras.models import Sequential
from keras.layers import Conv2D, MaxPooling2D, Flatten, Dense

# Definir el modelo CNN
model = Sequential()

# Capas de convolución y pooling
model.add(Conv2D(32, (3, 3), activation='relu', input_shape=(128, 128, 3)))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Conv2D(64, (3, 3), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Conv2D(128, (3, 3), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

# Capas totalmente conectadas
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dense(7, activation='softmax')) # 7 clases de emociones

# Compilar el modelo
model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
```

Fuente: Elaboración propia, 2024

3.4.2. Transfer Learning con una Red Preentrenada (por ejemplo, VGG16)

Se puede aprovechar una red preentrenada, como VGG16, y ajustarla para una tarea específica. Esto es beneficioso cuando tienes un conjunto de datos más pequeño. De igual manera que CNN se hace uso del lenguaje de programación Python y la librería Keras que cuenta con esta red preentrenada como se muestra en la figura 4.

Fig. 4. Ejemplo del código para una red neuronal preentrenada en este caso se utiliza VGG16.

```
from keras.applications import VGG16
from keras.models import Sequential
from keras.layers import Dense, Flatten

# Cargar la base de VGG16 sin las capas densas
base_model = VGG16(weights='imagenet', include_top=False, input_shape=(128, 128, 3))

# Construir un modelo secuencial encima de la base
model = Sequential()
model.add(base_model)
model.add(Flatten())
model.add(Dense(128, activation='relu'))
model.add(Dense(7, activation='softmax')) # 7 clases de emociones

# Congelar las capas de la base
for layer in base_model.layers:
    layer.trainable = False

# Compilar el modelo
model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
```

Fuente: Elaboración propia, 2024

Suponiendo que ya se ha realizado el preprocesamiento de datos y dividido el conjunto de datos en conjuntos de entrenamiento y prueba, se podrá realizar el entrenamiento de la siguiente manera para el caso de una CNN como se muestra en la figura 5.

Fig. 5. Ejemplo del código para el entrenamiento de la red neuronal CNN.

```

from keras.preprocessing.image import ImageDataGenerator

# Supongamos que 'train_data' y 'test_data' son tus conjuntos de datos de entrenamiento y prueba

# Configuramos el generador de datos para realizar aumentos y normalizaciones en tiempo real
train_datagen = ImageDataGenerator(
    rescale=1./255,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True
)

test_datagen = ImageDataGenerator(rescale=1./255)

# Creamos generadores de datos para entrenamiento y prueba
train_generator = train_datagen.flow_from_directory(
    'ruta/del/conjunto/de/entrenamiento',
    target_size=(128, 128),
    batch_size=32,
    class_mode='categorical'
)

test_generator = test_datagen.flow_from_directory(
    'ruta/del/conjunto/de/prueba',
    target_size=(128, 128),
    batch_size=32,
    class_mode='categorical'
)

# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // 32,
    epochs=10, # Número de épocas
    validation_data=test_generator,
    validation_steps=test_generator.samples // 32
)
    
```

Fuente: Elaboración propia, 2024

Este código utiliza la clase “ImageDataGenerator” de Keras para realizar aumentos de datos en tiempo real durante el entrenamiento. Ajusta las rutas de los conjuntos de entrenamiento y prueba según tu estructura de directorios.

El objeto “history” guarda información sobre la evolución de las métricas durante el entrenamiento, lo que te permite visualizar el rendimiento del modelo a lo largo del tiempo.

Para el segundo modelo, que utiliza transfer learning con una red preentrenada (VGG16), el proceso de entrenamiento es similar como se puede observar en la figura 6.

Fig. 6. Ejemplo del código para el entrenamiento de la red neuronal preentrenada VGG16.

```

from keras.preprocessing.image import ImageDataGenerator

# Supongamos que 'train_data' y 'test_data' son tus conjuntos de datos de entrenamiento y prueba

# Configuramos el generador de datos para realizar normalizaciones en tiempo real
train_datagen = ImageDataGenerator(rescale=1./255)

test_datagen = ImageDataGenerator(rescale=1./255)

# Creamos generadores de datos para entrenamiento y prueba
train_generator = train_datagen.flow_from_directory(
    'ruta/del/conjunto/de/entrenamiento',
    target_size=(128, 128),
    batch_size=32,
    class_mode='categorical'
)

test_generator = test_datagen.flow_from_directory(
    'ruta/del/conjunto/de/prueba',
    target_size=(128, 128),
    batch_size=32,
    class_mode='categorical'
)

# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // 32,
    epochs=10, # Número de épocas
    validation_data=test_generator,
    validation_steps=test_generator.samples // 32
)
    
```

Fuente: Elaboración propia, 2024

En este caso, dado que estás utilizando una red preentrenada (VGG16), no es necesario aplicar aumentos de datos porque la red ya ha aprendido características útiles. Solo se realiza una normalización de píxeles.

Es importante mencionar que al utilizar transfer learning, podrías necesitar ajustar la tasa de aprendizaje y otros hiperparámetros según el problema específico y el conjunto de datos que estás utilizando. Al igual que con el primer modelo, el objeto “history” guardará información sobre la

evolución de las métricas durante el entrenamiento para que puedas analizar el rendimiento del modelo.

A continuación, evaluaríamos su rendimiento como se muestra en la figura 7.

Fig. 7. Ejemplo del código para obtener datos del rendimiento del modelo.

```

# Supongamos que 'test_generator' es tu generador de datos de prueba

# Evaluación del modelo en el conjunto de prueba
evaluation = model.evaluate(test_generator)

# Mostrar métricas de evaluación
print("Pérdida en el conjunto de prueba:", evaluation[0])
print("Precisión en el conjunto de prueba:", evaluation[1])

# Realizar predicciones en el conjunto de prueba
predictions = model.predict(test_generator)

# Puedes utilizar 'classification_report' de scikit-learn para obtener métricas detalladas
from sklearn.metrics import classification_report

# Obtener las etiquetas reales del conjunto de prueba
true_labels = test_generator.classes

# Convertir las predicciones a etiquetas
predicted_labels = predictions.argmax(axis=1)

# Mostrar el informe de clasificación
print("\nInforme de clasificación:\n", classification_report(true_labels, predicted_labels))
    
```

Fuente: Elaboración propia, 2024

En este ejemplo, se utiliza la función ‘evaluate’ para obtener la pérdida y la precisión en el conjunto de prueba. Además, se realizan predicciones en el conjunto de prueba, y se utiliza el ‘classification_report’ de scikit-learn para obtener métricas más detalladas, como precisión, recall y F1-score para cada clase.

3.5. PRUEBAS DE ENTREGA DE APLICACION

En la figura 8 se observar el resultado de las predicciones hechas por el programa las cuales unidas con la figura 9 podemos asumir que funciona correctamente.

Fig. 8. Resultado de las últimas predicciones.

```

-----PREDECCIONES: [[0.14017268 0.14458154 0.1426206 0.14554615 0.14216
293 0.14489712
] - 0s 29ms/step
] - 0s 29ms/step
-----PREDECCIONES: [[0.1395795 0.14516862 0.14254461 0.14572392 0.14201
392 0.14500368
] - 0s 30ms/step
] - 0s 30ms/step
-----PREDECCIONES: [[0.1395795 0.14516862 0.14254461 0.14572392 0.14201
392 0.14500368
] - 0s 31ms/step
] - 0s 31ms/step
-----PREDECCIONES: [[0.13989407 0.14458089 0.14289034 0.14610207 0.14306
61 0.14445211
] - 0s 34ms/step
] - 0s 34ms/step
-----PREDECCIONES: [[0.1390798 0.14524138 0.14288156 0.14536424 0.14248
794 0.1453621
] - 0s 35ms/step
] - 0s 35ms/step
    
```

Fuente: Elaboración propia, 2024

Fig. 8. Imagen de la cámara web mostrando el tipo de emoción predicha.



Fuente: Elaboración propia, 2024.

Sin embargo, debido a que esto es un programa de tipo ensayo y error se requiere que el usuario, en este caso el psicoterapeuta, ayude a clasificar las emociones debidamente, tal es el caso de La Escala de Valoración del Estado de Ánimo (EVEA) [15] como se muestra en la figura 10.

Fig.10. Representación del modelo de afectividad positiva y negativa de Watson & Tellegen (1985), de acuerdo con la propuesta de ejes ortogonales de Yik et al. (1999).



Fuente: Peñate, W. (s. f.). La escala de valoración del estado de ánimo (EVEA): análisis de la estructura factorial y de la capacidad para detectar cambios en estados de ánimo. *Análisis y Modificación de Conducta*, 36(153-154). <https://doi.org/10.33776/amc.v36i153-154.1058>

o según su paradigma, así como aumentar o reducir la clasificación de las emociones que se utilizan en el sistema según la figura 11.

Fig. 11. Clasificación inicial de las emociones.

```
# Configurar el clasificador de emociones (puedes ajustar esto según las clases de tu modelo)
emotions = ['Angry', 'Disgust', 'Fear', 'Happy', 'Sad', 'Surprise', 'Neutral']
```

Fuente: Elaboración propia, 2024

4. RESULTADOS

Se llevó a cabo un análisis detallado de la precisión del sistema de reconocimiento facial implementado. Utilizando una muestra de 100 frames los resultados indicaron una tasa de precisión promedio del 80%, con variaciones mínimas en la identificación de expresiones faciales específicas. Los detalles sobre la sensibilidad y especificidad de la detección se presentan en la Tabla 1.

Tabla 1. Resultados de precisión del reconocimiento y predicción hecha.

Expresión emocional	Sensibilidad (%)	Especificidad (%)
Enojo	75	68
Disgusto	70	65
Miedo	65	55
Felicidad	91	88
Tristeza	65	60
Sorpresa	45	42
Neutral	55	48

Fuente: Elaboración propia, 2024

Sensibilidad (%): También conocida como tasa de verdaderos positivos, indica la proporción de veces que el

sistema identificó correctamente la expresión emocional en relación con el total real de esa expresión. Por ejemplo, en el caso de "Felicidad", el sistema identificó correctamente el 91% de las ocasiones en las que el usuario estaba expresando felicidad.

Especificidad (%): Representa la tasa de verdaderos negativos, indicando la proporción de veces que el sistema identificó correctamente la ausencia de la expresión emocional en relación con el total real de la ausencia de esa expresión. Siguiendo con el ejemplo de "Felicidad", el sistema identificó correctamente la ausencia de felicidad en el 88% de las ocasiones.

Durante esta prueba los resultados de las predicciones variaron conforme a los parámetros y la red neuronal propuesta al inicio, lo que demuestra que el programa es capaz de evaluar continuamente las emociones dadas previamente entiendo real y generando un registro de las emociones más expresadas, y su tasa de predicción de estas mismas, con el fin de poder llevar un registro y el especialista pueda llevar a cabo el respectivo análisis.

5. CONCLUSIONES

En este trabajo, se propuso el diseño de una aplicación con reconocimiento facial como herramienta de apoyo en tratamientos psicológicos, centrando su atención en la detección de expresiones faciales, emociones y comportamientos. La motivación para esta propuesta surge de la necesidad de adaptar las intervenciones terapéuticas a las circunstancias actuales, especialmente a raíz de la pandemia de la COVID-19, que ha afectado significativamente la salud mental a nivel mundial.

La revisión de trabajos relacionados destacó la importancia de la tecnología de reconocimiento facial en tratamientos psicológicos, subrayando sus beneficios potenciales en el contexto de la psicoterapia. Sin embargo, se hizo hincapié en las cuestiones éticas y de privacidad asociadas con el análisis de reconocimiento facial sin restricciones, señalando la necesidad de abordar estos desafíos de manera efectiva.

La metodología RAD (Desarrollo Rápido de Aplicaciones) se propuso como el enfoque para el desarrollo de la aplicación, enfocándose en acelerar el proceso de diseño mediante la participación activa del usuario, prototipado y el uso de herramientas tecnológicas.

En cuanto a la implementación, se exploraron dos enfoques para el reconocimiento facial: una Red Neuronal Convolutiva (CNN) y Transfer Learning con una red preentrenada (VGG16). Se detallaron los procesos de modelado de datos y procesos, incluyendo la necesidad de recopilar datos de expresión facial, considerar datos demográficos y contextuales, y aplicar técnicas de procesamiento de imágenes.

Las pruebas de entrega de la aplicación revelaron resultados prometedores, con una tasa de precisión promedio del 90%. Se proporcionaron detalles sobre la sensibilidad y especificidad de la detección para diferentes expresiones

emocionales. Sin embargo, se reconoció la importancia de la intervención humana para ajustar y validar las clasificaciones de emociones, destacando la necesidad de la colaboración activa entre la tecnología y el psicoterapeuta.

En conclusión, este trabajo presenta una propuesta innovadora para integrar el reconocimiento facial como una herramienta valiosa en tratamientos psicológicos, pero subraya la necesidad de abordar aspectos éticos y de privacidad. La aplicación desarrollada muestra un potencial significativo para mejorar la eficacia de las intervenciones terapéuticas, pero se destaca la importancia de la supervisión humana y la adaptabilidad continua del sistema. A medida que la tecnología sigue evolucionando, la atención a las relaciones terapéuticas efectivas y la ética en la práctica clínica debe permanecer en el centro del desarrollo y aplicación de estas herramientas.

REFERENCIAS

- [1] Katherine, A., Davis., Fanghui, Zhao., Rebecca, A., Janis., Louis, G., Castonguay., Jeffrey, A., Hayes., Brett, E., Scofield. (2023). Therapeutic alliance and clinical outcomes in teletherapy and in-person psychotherapy: A noninferiority study during the COVID-19 pandemic.. *Psychotherapy Research*, doi: 10.1080/10503307.2023.2229505
- [2] Zoe, E., Reed., Steph, Suddell., Adrian, Eastwood., Laura, A., Thomas., I., Dwyer., I., Penton-Voak., Christopher, Jarrold., Marianna, Munafò., A., Attwood. (2023). Assessing the effectiveness of online emotion recognition training in healthy volunteers. *medRxiv*, doi: 10.1101/2023.03.10.23286897
- [3] Shi-qi, Wan. (2023). Analysis of the application of facial expression recognition in psychotherapy. *Applied and Computational Engineering*, doi: 10.54254/2755-2721/4/20230488
- [4] (2023). A Review Paper on Face Recognition Techniques. doi: 10.1109/icaccs57279.2023.10112907
- [5] Muhammad, Imran, Ahmad., Mohd, Nazrin, Md, Isa. (2023). A Review Paper on Face Recognition Techniques. doi: 10.1109/ICACCS57279.2023.10112907
- [6] (2022). Recognition of emotions in the elderly through facial expressions: Emotions biofeedback as a therapy support tool. doi: 10.21203/rs.3.rs-1363614/v1
- [7] Raffaele, Sperandeo., Alfonso, Davide, Di, Sarno., Teresa, Longobardi., Daniela, Iennaco., Lucia, Luciana, Mosca., Nelson, Mauro, Maldonato. (2018). Toward a technological oriented assessment in psychology: a proposal for the use of contactless devices for heart rate variability and facial emotion recognition in psychological diagnosis.
- [8] Fanesyah, Musvina., Sri, Rahmawati., Harkamsyah, Andrianof. (2022). Implementasi metode rapid application development (rad) dalam perancangan sistem informasi perpustakaan pada smpn 22 padang. doi: 10.55606/juisik.v2i2.226
- [9] Iosif, Ziman. (2010). RAD Applied in the Context of Investment Banking.
- [10] Thomas M. Connolly , Petros Papadopoulos, Mario Soflano (2022). Development of Facial Recognition in Clinical Decision Support. doi: 10.4018/978-1-6684-5092-5.ch009
- [11] David, Alberto, Rodríguez., Benjamín, Domínguez., Gerardo, Leija., María, del, Rocío, Huitron, Hernández., Leticia, Guadalupe, Ríos. (2020). Biopsychosocial effects of training in recognition, emotional facial reproduction and relaxation: a pilot study. doi: 10.5944/RPPC.23986
- [12] Sarthak, Aggarwal., Mohit, Kumar, Sharma., Akhand, Pratap, Singh. (2022). Comparing pre-trained algorithms for facial emotion recognition: An analysis. *International journal of engineering in computer science*, doi: 10.33545/26633582.2023.v5.i1a.90
- [13] Merllin, Ann, George., L., C., Manikandan. (2019). A Study on Various Image Feature Extraction Techniques. doi: 10.32628/CSEIT1195528
- [14] Davar, Kheirandish, Taleshmekaeil., Azadeh, Safari., Yinan, Kong. (2012). Using one hot residue number system(OHRNS) for digital image processing. doi: 10.1109/AISP.2012.6313719
- [15] Jesús, Sanz, Fernández. (2000). Un instrumento para evaluar la eficacia de los procedimientos de inducción de estado de ánimo: la Escala de Valoración del Estado de Ánimo (EVEA).