

Prototipo para el reconocimiento de video en tiempo real de los ejercicios del método *Klapp* usando redes neuronales recurrentes

Prototype for real-time video recognition of Klapp method exercises using recurrent neural networks

Néstor Andrés García Rojas¹ , Verónica Moreno Jiménez² , Rubelia Isaura Martínez Téllez³ ,

Gudelia Pilar Pérez Conde⁴ , Gabriela Rabanales Gómez⁵,

^{1,2}Ingeniería en Software y ^{3,5}Licenciatura en Terapia Física, Universidad Politécnica de Amozoc, Av. Ampliación, Luis Oropeza No. 5202, San Andrés las Vegas 1ra Secc, 72980 Amozoc, Puebla.

⁴Ingeniería en Tecnologías de la Información, Universidad Politécnica de Puebla, Tercer Carril del Ejido, Serrano S/N, Cuanalá, 72640 Puebla, Puebla.

* Correo-e: gudelia.perez353@uppuebla.edu.mx

PALABRAS

CLAVE: RESUMEN

Redes Recurrentes, Inteligencia Artificial, Método Klapp, Telerehabilitación, Fisioterapia, Rehabilitación

En la actualidad la telerehabilitación ha tomado un gran auge debido a los acontecimientos de la COVID-19, éste trata de la aplicación de un programa bajo la supervisión remota, usando las tecnologías de información y comunicación, eliminando limitantes de las personas para su desplazamiento, minimizando riesgos y aportando mayor cumplimiento a los programas de rehabilitación y reacondicionamiento. El presente trabajo propone el desarrollo de una herramienta para el reconocimiento en tiempo real de ejercicios del método fisioterapéutico Klapp, basándonos en el concepto de telerehabilitación. El objetivo de este proyecto es dar apoyo a los fisioterapeutas para dar seguimiento al tratamiento de rehabilitación o reacondicionamiento. La herramienta permite evaluar la ejecución en tiempo real de cada uno de los ejercicios para informarle al paciente si lo realizó correctamente, y el fisioterapeuta podrá consultar dichos resultados.

El desarrollo del proyecto fue gestionado bajo el modelo V como referencia para cada una de las actividades realizadas. La técnica utilizada para el reconocimiento son las redes neuronales recurrentes, pues su arquitectura permite modelar la siguiente predicción basándose en la información pasada y lograr modelar datos en secuencia como videos. Y para la implementación fueron empleadas las herramientas Keras, TensorFlow, Python, librerías de OpenCV y OpenPose, con el cual se obtuvieron los puntos de referencias de los ejercicios basándonos en los ángulos de Cobb.

Los resultados obtenidos de reconocimiento de la red recurrente fueron medidos bajo la métrica de exactitud (Accuracy), logrando un 97% considerando 6 ejercicios, los cuales comprenden los ejercicios del método Klapp.

KEYWORDS:

ABSTRACT

Recurrent Neural Networks, Artificial Intelligence, Klapp Method, Telerehabilitation, Physiotherapy, Rehabilitation.

At present, telerehabilitation has taken a great boom due to the events of COVID-19, which deals with the application of a program under remote supervision, using information and communication technologies, eliminating people's moving limitations, minimizing risks and providing greater compliance with rehabilitation and reconditioning programs. The present work proposes the development of a tool for the real-time recognition of exercises of the *Klapp* physiotherapeutic method, based on the concept of remote rehabilitation. The objective of this project is to provide support to physiotherapists to follow up rehabilitation or reconditioning treatment. The tool allows to evaluate the execution in real time of each of the exercises to inform the patient if it was performed correctly, and the physiotherapist will be able to review the results.

The development of the project was managed under the V model as a reference for each of the activities performed. The technique used for recognition is recurrent neural networks, since their architecture allows modeling the next prediction based on past information and modeling data in sequence as videos. For the implementation, the tools Keras, TensorFlow, Python, and libraries of OpenCV and OpenPose were used to obtain the reference points of the exercises based on the Cobb angles.

The results obtained for recurrent network recognition were measured under the *accuracy* metric achieving 97% considering 6 exercises, which comprise the *Klapp* method exercises

Recibido: 15 de julio de 2022 • **Aceptado:** 3 de febrero de 2022 • **Publicado en línea:** 12 de agosto de 2022

1 INTRODUCCIÓN

La tecnología y la medicina siguen un camino paralelo durante las últimas décadas. Los avances tecnológicos van modificando el concepto de salud y las necesidades sanitarias están influyendo en el desarrollo de la tecnología. Alguno de los conceptos implementados hoy en día es la telerehabilitación, término que hace referencia al uso de tecnologías de la información y la comunicación (TICS) para realizar un servicio de rehabilitación de forma remota, ya sea en casa o en algún otro entorno [1]. Para el desarrollo de las nuevas tecnologías, la inteligencia artificial (IA) también ha ido evolucionando hasta convertirse en un elemento esencial para la creación de nuevos dispositivos, herramientas y mecanismos donde las múltiples utilidades que se pueden llegar a tener con la IA, hacen de ésta una tecnología muy versátil, aplicable a infinitos ámbitos y sectores.

La inteligencia artificial (IA) está formada por una serie de algoritmos lógicos suficientemente entrenados a partir de los cuales las máquinas son capaces de tomar decisiones para casos concretos [2]. En la medicina está optimizando el procesamiento de datos médicos ofreciendo numerosas ventajas como por ejemplo disminuir el margen de error en diagnósticos médicos, seguimiento de rehabilitación, en procesos para detectar patologías con anticipación [3][4], permitiendo automatizar tratamientos o aplicarlos a distancia [5][6]

En el área de la IA, una de las técnicas utilizadas son las redes neuronales artificiales, las cuales pueden tener variantes. En este proyecto se usaron las redes neuronales recurrentes para reconocer los ejercicios del método *Klapp* que ayudan o sirven para corregir tipos de deformación vertebral o con fines de fortalecimiento muscular.

La ejecución del método *Klapp* sólo podrá corregir en ciertas categorías o grado de deformidad, sin embargo, puede evitar que siga avanzando y deformar aún más la columna vertebral de la persona llegando al punto de influir en la marcha, estos ejercicios tienen su efecto según la precisión, la amplitud y el ritmo con que se ejecutan, todo lo anterior permite lograr la flexibilidad y fuerza muscular [7]. Para determinar el mejor tratamiento es importante identificar ciertos factores, tales como la debilidad muscular, el tipo de curvatura en columna vertebral, la edad del paciente, la actividad que realiza, y los hábitos diarios, con el fin de mejorar la postura lumbar y fortalecer los músculos, además, se pueden trabajar a la par con otros métodos como los ejercicios isométricos, isotónicos excéntricos y concéntricos.

La propuesta del proyecto es desarrollar un prototipo web para el reconocimiento en tiempo real de ejercicios del método *Klapp* usando una red neuronal recurrente simple, con las herramientas de Python, Keras, Tensorflow, OpenCV, MySQL y Django, y para la extracción de los puntos o coordenadas la librería de OpenPose.

En las siguientes secciones se presentan los trabajos relacionados al proyecto, la metodología, la descripción general del sistema, pruebas y resultados, finalmente se presenta las conclusiones y el trabajo futuro.

2 TRABAJOS RELACIONADOS

En esta sección, se revisaron algunos de los trabajos enfocados en el reconocimiento de movimiento o ejercicios usando videos para el área del fitness o bien para rehabilitación aplicando diferentes tipos de redes neuronales artificiales.

Jinnovart et al. en 2020 [8] Reconocimiento anormal de la marcha en tiempo real mediante redes neuronales recurrentes simples, de memoria a corto plazo a largo plazo (LSTM) y red de unidad recurrente cerrada (GRU). Extraen 135 puntos clave del cuerpo humano usando OpenPose. La red reconoce 5 tipos de anomalías en la marcha. Cada variante obtuvo una exactitud (*accuracy*) de 73.4%, 82% y 81.6%, donde se aprecia que el modelo que mejores resultados alcanzó fue la variante LSTM.

Alatiah y Chen en 2020 [9], realizaron un proyecto para analizar el rendimiento y dar una retroalimentación sobre las repeticiones de los ejercicios realizados en tiempo real usando redes neuronales, dicho propuesta puede ayudar a ayudar a jueces para contar las repeticiones de cualquier ejercicio durante el levantamiento de pesas o competiciones de *CrossFit*. Esta propuesta logró un 98.4% de exactitud (*accuracy*) en el reconocimiento de ejercicios, para su implementación utilizaron python, *OpenPose*, y un conjunto de 317 videos extraídos de UCF101, con total de 34501 puntos clave.

Jarrín en 2020 [10], usaron una red neuronal convolucional pre entrenada que ha sido entrenada en aproximadamente 1.2 millones de imágenes y el Algoritmo de Estimación de Pose Humana (*OpenPose*), propone un sistema de detección del ángulo articular en los movimientos de miembro superior para evaluación en fisioterapia mediante visión artificial, éste logró un nivel de confiabilidad del 92,60%, implementado con python y tensorflow.

Obaid et al. en 2020 [11], utilizaron redes neuronales convolucionales profundas (CNN) y recurrentes (LSTM) para el reconocimiento de gestos con las manos en secuencias de video, en su trabajo crearon dos modelos para determinar la arquitectura óptima de CNN y LSTM. El modelo uno obtuvo un 82% de precisión trabajando con el canal de color y un 89% con el canal de profundidad, sin embargo, el segundo modelo logró 93% de precisión trabajando con el canal de color y profundidad. Para los experimentos usaron el conjunto de datos VIVA para probar los modelos.

Leightley et al. en 2017 [12], proponen un framework que evalúa los movimientos clínicamente válidos para identificar el comportamiento inestable durante la ejecución utilizando redes neuronales convolucionales profundas usando el Kinect, para llevar a cabo este proyecto se utilizó el conjunto de datos K3Da, el cual consta de más de 500 movimientos capturados a 30 Hz con el sensor *Kinect One*, este sistema logró un 96.20% de exactitud (*accuracy*).

Rodríguez en 2012 [13], nos habla que la telerehabilitación puede ser una alternativa rentable de prestación de servicios a distancia, es así que Barrios en 2019 [14], presenta la combinación de estos procedimientos de intervención con la tecnología del videojuego, ha demostrado ser más eficaz y motivadora.

Sumando que los dispositivos y tecnologías emergentes

reutilizables son una herramienta de bajo costo para vigilar los aspectos biológicos y biocinemáticos de los seres humanos [15]. El intercambio de datos entre múltiples sistemas de tele-salud es un enfoque adaptativo para mejorar la calidad del servicio a través de las tecnologías basadas en la red [16].

Las aplicaciones móviles son otra fuente de empleo para el mundo de los tratamientos, información, rutinas de la salud [1]. Dentro de este marco y tomando como antecedente para el proyecto se consideraron algunas de las aplicaciones ya existentes como: Columna vertebral sana y postura recta [17], la cual permite el entrenamiento para dolor de espalda baja, fortalecerlos y hacerlos flexibles; Dolor de espalda [18] [19], éste ayuda en el tratamiento y la prevención de enfermedades de la espalda y el cuello en el hogar.

De acuerdo con la investigación de trabajos relacionados, se encontraron propuestas enfocadas en la reducción del dolor lumbar, dorsal y cervical, o en el seguimiento de ejercicios *fitness*, sin embargo, no se encontró alguna página web o aplicación donde se muestre cómo realizar los ejercicios de *Klapp* para el fortalecimiento lumbar y que además se verifiquen a través del sistema en tiempo real.

3 METODOLOGÍA

En este apartado se abordarán los conceptos, procesos y conjunto de datos para el desarrollo del proyecto.

Redes Neuronales Recurrentes

Las redes neuronales recurrentes, o *Recurrent Neural Networks* (RNN) por sus siglas en inglés, son una clase de redes para analizar datos de series temporales permitiendo tratar la dimensión de “tiempo”. Las redes neuronales tradicionales tienen una función de activación que solo actúa en una dirección, hacia adelante, desde la capa de entrada hacia la capa de salida, es decir, que no recuerdan valores previos [20]. Una red RNN es parecida, solo que adicionalmente presentan conexiones cíclicas en sus nodos, es decir que propaga información tanto hacia las siguientes capas como a sí mismas, esto permite modelar tomando en cuenta información pasada para su siguiente predicción y lograr modelar datos en secuencia como los videos [21].

Dado que la salida de una neurona recurrente en un instante de tiempo determinado es una función de entradas de los instantes de tiempo anteriores, se podría decir que una neurona recurrente tiene en cierta forma memoria. Y precisamente esta “memoria interna” es lo que hace de este tipo de redes muy adecuadas para problemas de aprendizaje automático que involucran datos secuenciales. Gracias a su memoria interna, las RNN pueden recordar información relevante sobre la entrada que recibieron, lo que les permite ser más precisas en la predicción de lo que vendrá después [22].

Una red neuronal recurrente utiliza una memoria con estado, lo que le permite almacenar datos a medida que realiza cálculos. Sin embargo, una red neuronal regular no puede almacenar datos y solo puede procesar la información de forma secuencial. Con la capacidad de memoria adicional a las RNN pueden tener un mejor desempeño en tareas, como el reconocimiento de imágenes.

Una de las ventajas de utilizar RNN es que se logrará un mejor entrenamiento debido a la memoria con la que se cuenta, logrando una precisión aceptable con pocas épocas de entrenamiento y nos permite realizar un análisis de manera más rápida, logrando una mejor ejecución del sistema.

Modelo V

El modelo V, fue propuesto por Alan Davis a principios de los 90, éste se basa en el modelo en cascada con la innovación de procurar actividades de pruebas más efectivas y productivas mediante la introducción de validaciones en la medida en que se avanza en el proyecto, con este cambio las pruebas se comienzan a realizar lo más pronto posible en el ciclo de vida, llevándolas en paralelo con las actividades de desarrollo [23].

Este modelo presenta una secuencia de pasos para el desarrollo del ciclo de vida de un proyecto, en esta secuencia se describen las actividades que se deben seguir para el desarrollo del proyecto (Figura 2). Éste es representado con la letra mayúscula V (Verificación y Validación)

Se inicia con las necesidades del usuario en el extremo izquierdo y finalizando con un sistema validado por el usuario en el extremo derecho. En el costado izquierdo, la descomposición y la definición descienden como en el modelo en cascada, mientras que, en el costado derecho, la integración y verificación ascienden sucesivamente pasando por los diferentes niveles, es decir, en el ascenso se verifican los conjuntos, unidades, componentes, subsistemas y finalmente el sistema completo [24].

Los objetivos que abarca este modelo V son:

- Minimización de los riesgos del proyecto
 - Mejora y Garantía de calidad
 - Reducción de gastos durante el proyecto y sistema del ciclo de vida.
 - Mejora la comunicación entre todos los inversionistas.
- Ventajas
- La relación entre las etapas de desarrollo y los distintos tipos de pruebas facilitan la localización de fallos.
 - Es un modelo sencillo y de fácil aprendizaje
 - Hace explícito parte de la iteración y trabajo que hay que revisar
 - Especifica bien los roles de los distintos tipos de pruebas a realizar
 - Involucra al usuario en las pruebas

Desventajas

- Es difícil que el cliente exponga explícitamente todos los requisitos
- El cliente debe tener paciencia pues obtendrá el producto al final del ciclo de vida
- Las pruebas pueden ser caras y, a veces, no lo suficientemente efectivas
- El producto final obtenido puede que no refleje todos los requisitos del usuario

Método Klapp

El método *Klapp* es una técnica para el tratamiento de la escoliosis muy antiguo que data de principios del siglo XX en el año 1905, por Rudolf *Klapp* (1873-1949), quien fue un

cirujano alemán que basó su tratamiento en las deformidades de columna vertebral, pero con una particularidad ya que todos los ejercicios fueron diseñados en posición de cuadrúpeda. Es el método en el cual se utiliza una posición de descarga, siendo esta en cuatro puntos de apoyo con el fin de crear a través de la gravedad la suspensión de la columna vertebral y de esta forma evitar la tensión de la musculatura de la misma [25]. El método, es una serie de ejercicios terapéuticos mayormente utilizados para corregir todo tipo de desviaciones vertebrales tanto funcionales como vertebrales, entre estas desviaciones encontramos la escoliosis. El método no hace diferencia según el tipo de deformidad; ya que éstas se dan a causa de la posición de bipedestación del ser humano, debido a la presión que ejerce la fuerza de gravedad sobre la espina dorsal, ésta posición facilita el desequilibrio de la estática vertebral dando lugar a desviaciones laterales o antero-posteriores.

Los ejercicios *Klapp* se fundamentan en la movilidad de la columna vertebral a partir de la posición de cuatro puntos o tetrapodía, esta postura brinda útiles ventajas, como lo es la eliminación de la gravedad sobre la columna, así como dar mayor estabilidad y por lo tanto permite corregir más fácilmente la curva escoliótica [26].

El método de *Klapp* consta de la colocación del paciente en posición de gateo y el desarrollo posterior de 6 ejercicios para el tratamiento de deformidades en el plano lateral, como son la hipercifosis dorsal e hiperlordosis lumbar, cabe mencionar que sus resultados son demasiado buenos comparados con los tratamientos de escoliosis por este método [7]. Sin embargo también alcanzan otros fines ya que son utilizados para generar efectos de estiramiento y fortalecimiento muscular incidiendo sobre postura, tronco, movilidad y dolor musculoesquelético.

El método de *Klapp* consta de 6 posiciones de inclinación (ver Figura 2) posibles según el nivel de la acción correctora o para fortalecer:

- Posición baja (PB):** la cintura escapular se hunde entre los dos antebrazos situados verticalmente, mientras que la región lumbar queda fuertemente bloqueada en cifosis, la columna dorsal superior desde D1 a D4 puede ser movilizada selectivamente en lordosis.
- Posición semi baja (PSM):** se sitúa la cintura escapular en la horizontal que pasa por los brazos, permaneciendo la región lumbar en cifosis, puede moverse la columna dorsal en lordosis, va hacia D5 ± D7.
- Posición horizontal (PH):** los músculos y los miembros superiores están verticales, la movilización máxima se sitúa hacia D8 ± D10.
- Posición semi erguida (PSE):** el paciente se apoya sobre las rodillas y los puños cerrados, la movilización en lordosis desciende hacia D10 - D12.- L1, el dorso está recto o en cifosis.
- Posición erguida (PE):** el paciente se apoya sobre el dorso de los dedos, la movilización en lordosis hacia L1 ± L3 pudiendo el dorso estar recto en cifosis.
- Posición invertida (PI):** el paciente no se apoya con las manos, los miembros superiores están dirigidos levemente hacia atrás, dependiendo si el dorso es mantenido o no en cifosis, el máximo de lordosis se

sitúa entre L4 ± S1.

Conjunto de datos

Para el entrenamiento de la RNN se utilizaron 6 videos que fueron grabados por alumnos y revisados por docentes del área de Terapia Física de la Universidad Politécnica de Amozoc (UPAM), cumpliendo los siguientes requisitos de grabación (ver Tabla 1) para garantizar un buen reconocimiento de cada una de las rutinas de *Klapp*.

Cabe mencionar que son pocos videos para tener un modelo robusto de reconocimiento de ejercicios *Klapp*, ya que no se ha considerado las diferentes variables como son el peso, la talla, edad y posición; sin embargo, para este prototipo fue funcional la cantidad de videos; no obstante, para garantizar la robustez del reconocimiento de video en tiempo real de las rutinas de *Klapp*, se debe proporcionar una mayor gran cantidad de información para el entrenamiento de la red neuronal.

Para el entrenamiento se utilizaron 2949 puntos clave de cada articulación del cuello, hombros, codos, muñecas, cadera, rodillas, tobillos, ojos, orejas y nariz de ambos lados, izquierda y derecha que corresponden a cada uno de los ejercicios, con 14 clases para identificar la posición correcta o incorrecta. En la tabla 2., se muestra la cantidad de datos obtenida para cada clase.

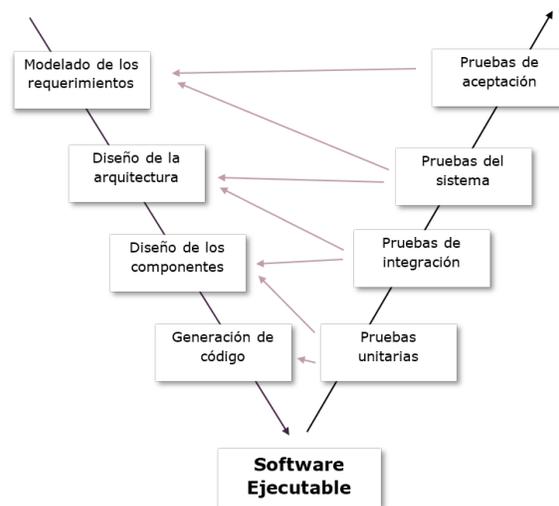


Figura. 1 Metodología de Modelo V.

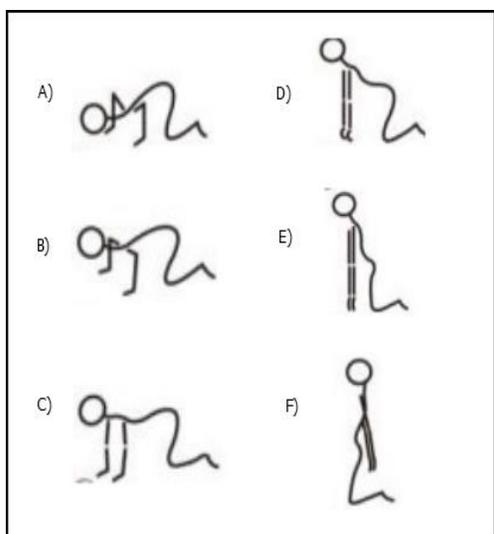


Figura. 2. Posiciones método Klapp [27]

Tabla 1. Requisitos de grabación.

Requisitos de grabación	Cámara a 90 grados Fondo Blanco y sin objetos en el entorno Grabar frente a la cámara en posición lateral
Características físicas de la persona	Género masculino y femenino Complexión Delgado (a) Peso no mayor a 60 kilos mujeres y 70 kilos hombres Edad de 19 a 30 años
Vestimenta	Ropa ajustada

Tabla 2. Cantidad de puntos clave por clase.

Número de ejercicio	Cantidad	Clase	Descripción
0	149	0	ninguna posición
0	700	1	Posición inicial
1	100	2	PB_Incorrecto
1	250	3	PB_Correcto
2	100	4	PSM_Incorrecto
2	250	5	PSM_Correcto
3	100	6	PH_Incorrecto

Número de ejercicio	Cantidad	Clase	Descripción
3	250	7	PH_Correcto
4	100	8	PSE_Incorrecto

4	250	9	PSE_Correcto
5	100	10	PE_Incorrecto
5	250	11	PE_Correcto
6	100	12	PI_Incorrecto
6	250	13	PI_Correcto

Descripción General del Sistema

En los diagramas de casos de uso y secuencia se muestra la interacción que tendrá el paciente y Fisioterapeuta dentro del sistema. En la Figura 3, se presentan las diferentes opciones que tendrá cada uno de los actores, en donde se observa que el paciente tiene dos opciones, una para realizar la rutina en vivo o bien subir el video de sus rutinas, mientras que el Fisioterapeuta podrá revisar la ejecución de dichas rutinas para validar su ejecución como experto del área. Y en la Figura 4, se muestra la secuencia a seguir cuando el paciente ejecutará una rutina en vivo.

4 ENTRENAMIENTO Y RECONOCIMIENTO DE LA RED NEURONAL RECURRENTE

Entrenamiento

Para el entrenamiento de la red neuronal recurrente, se realizaron los siguientes pasos (Figura 5):

- Definición de la Arquitectura de la RNN

La arquitectura utilizada en este proyecto fue un modelo secuencial, el número de capas ocultas fue determinado bajo las reglas empíricas de Jeff Heaton [28], quien menciona los siguientes puntos a considerar:

- Ninguna capa: Solo es capaz de representar funciones o decisiones lineales separables.
- Una capa: Puede aproximar cualquier función que contenga un mapeo continuo de un espacio finito a otro.
- Dos capas: Puede representar un límite de decisión arbitrario con precisión arbitraria con funciones de activación racionales y puede aproximar cualquier mapeo uniforme con cualquier precisión.
- Mayor a dos capas: Las capas adicionales pueden aprender representaciones complejas para capas de capas.

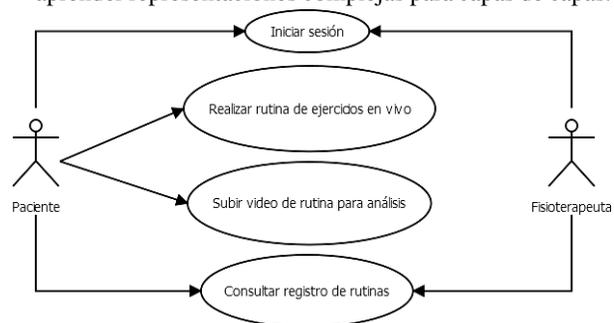


Figura. 3. Diagrama de Casos de Uso del Sistema

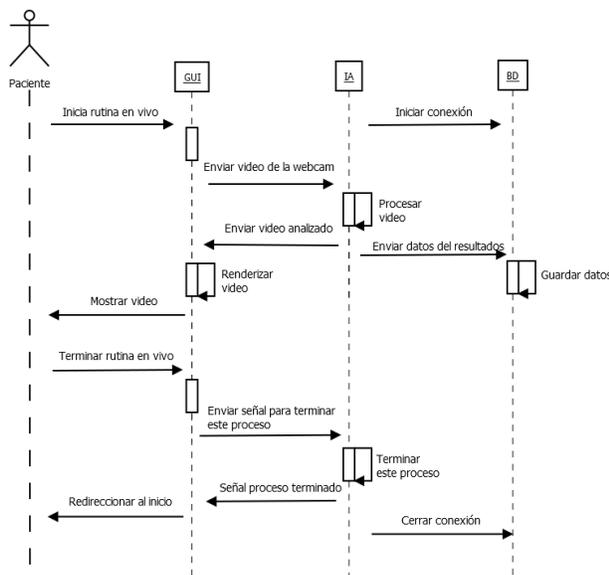


Figura. 4. Diagrama de Secuencia ejecución de rutina en vivo

Por lo tanto, se definieron 3 capas ocultas, las cuales analizan la posición en tiempo real de cada uno de los ejercicios de método *Klapp* usando los ángulos de Cobb, estos son las coordenadas que corresponden a cada uno de los puntos articulares de acuerdo al ejercicio realizado.

Finalmente, la arquitectura implementada de la red recurrente fue la siguiente: una capa con 36 neuronas de entrada; una capa con 128 neuronas ocultas, con función de activación “relu”; una capa con 64 neuronas ocultas, con función de activación “relu”; una capa con 16 neuronas ocultas, con función de activación “relu”; y una capa de salida con 14 neuronas, con función de activación “softmax” como se muestra en la Figura 5.

Para la implementación y funcionamiento de la red neuronal recurrente (RNN) se utilizó la librería Keras, dicha librería permite trabajar las redes neuronales, así como también aprovechar los recursos de CPU, GPU, RAM que se tienen disponibles para este tipo de tareas.

- Creación del archivo (.CSV) con las coordenadas de las articulaciones

Para entrenar a la RNN se crea un archivo en formato .CSV, el cual contiene las coordenadas de los puntos articulares en los ejes X y Y, estos puntos articulares son: cuello, hombros, codos, muñecas, cadera, rodillas, tobillos, ojos, orejas y nariz (ver Figura 8). Y además se tiene un valor llamado “clase” el cual representa el tipo de ejercicio al que pertenecen dichas coordenadas, este parámetro nos permite utilizar esta red neuronal para diferentes ejercicios.

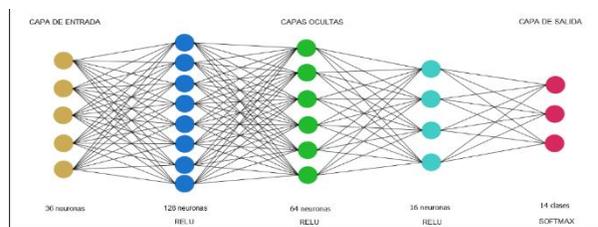


Figura. 5. Arquitectura de la RNN

- Entrenamiento de la RNN

Como siguiente paso se abre el archivo CSV que contiene las coordenadas en X-Y de los puntos articulares de los ejercicios que se van a entrenar, cada grupo de coordenadas, tiene una clase que se representa con un número entero, pasamos este archivo a la red neuronal para que sea entrenada, en la configuración del entrenamiento determinamos cada clase que hayamos ingresado en el archivo, con la posición, ejercicio, y si está correcto o incorrecto, el punto de “comparación”, de acuerdo al resultado del entrenamiento se deben de ajustar es decir se cambia la configuración del entrenamiento (ver Tabla 3, columna épocas), para volver a realizar el entrenamiento, y finaliza cuando se hayan logrado resultados mayores al 90% de exactitud.

El entrenamiento de la RNN con la arquitectura implementada tuvo un buen desempeño con un 97% de precisión en el entrenamiento y con una pérdida del 3% en el entrenamiento, no obstante, aún se debe mejorar los parámetros del entrenamiento, ya que como se muestra en la Figura 7., a partir de la época 60 deja de tener cambios significativos. Y también es necesario proporcionar más videos para mejorar el reconocimiento de ejercicios *Klapp* usando nuevos videos para la prueba.

- Archivo con los pesos del entrenamiento. Finalmente, cuando el entrenamiento logró los resultados deseados se genera un archivo con los pesos del entrenamiento, que se usa para poder ejecutar la red neuronal y realizar el reconocimiento de las posiciones.

Proceso de Reconocimiento

La tarea de reconocimiento de la RNN consiste en el aprendizaje de las coordenadas de los puntos articulares (ángulos de Cobb) para determinar el tipo de ejercicio y si se ejecutó de manera satisfactoria o no, como se muestra en la Fig 6. Para la identificación de las coordenadas en el video se utilizó la librería OpenCV y OpenPose.

Además, se utiliza un contador mayor a 26, dado que los videos tienen un tamaño estándar de 23 fotogramas por segundo, por consiguiente, si por cada fotograma las coordenadas de los puntos articulares cambia, entonces en el único momento que no cambiaría sería al llegar a la postura final del ejercicio, además de que la tendrá que mantener la posición al menos 1 segundo. Por otra parte, el uso de las clases y los contadores, nos permiten analizar más de una repetición del mismo ejercicio, así como diferentes ejercicios en una misma rutina o video.

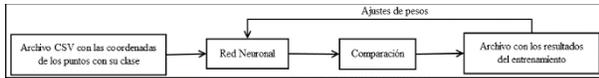


Figura 6. Pasos para el entrenamiento de la RNN

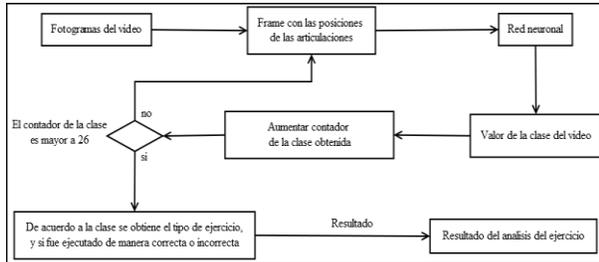


Figura 7. Proceso de Reconocimiento de la RNN

5 PRUEBAS Y RESULTADOS

Los resultados del entrenamiento de la RNN utilizando un conjunto de 2949 puntos clave, se muestran en la Tabla 3, para cada prueba se utilizaron diferentes parámetros de ajuste con la finalidad de lograr resultados mayores a 90%, como se muestra en la tabla, una prueba con 400 épocas apenas alcanza un 88%, a diferencia de usar sólo 100 épocas se logra un 97% de exactitud y con un error del 3%; aunque aún se podría reducir más el número de épocas, ya que como se muestra en la gráfica a partir de la época 60 los resultados ya no cambian significativamente.

Los resultados obtenidos fueron satisfactorios ya que la RNN logró identificar cada uno de los ejercicios del método *Klapp*, es decir no confundió un ejercicio con otro; en la interfaz del sitio web, en el apartado de verificar si el ejercicio fue ejecutado de manera correcta o incorrecta fue satisfactorio (ver Figuras 8-11).

Las pruebas se realizaron en un entorno controlado, es decir los ejercicios se realizaron de manera correcta e incorrecta a propósito para determinar la precisión final que tiene el sistema, en las pruebas se realizaron 5 rutinas de ejercicios con 4 repeticiones cada una, en las cuales dos repeticiones se hicieron de manera correcta y dos de manera incorrecta, además de que estas se realizaron de manera intercalada, para determinar si el sistema era capaz de diferenciar entre ejercicios.

Número de Prueba	Épocas	Exactitud %
1	Sin ajuste	80
2	400	88
3	100	97

Tabla 3. Resultados del entrenamiento de la RNN.

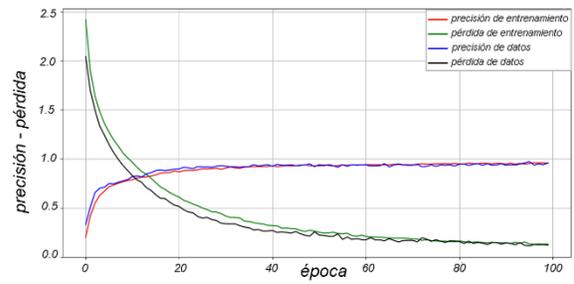


Figura 7. Gráfica de resultados del entrenamiento de la red neuronal

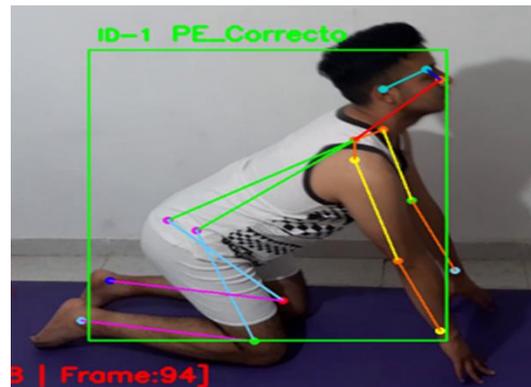


Figura 8. Resultado ejercicio PE reconocido correctamente



Figura 9. Resultado ejercicio PI reconocido incorrectamente

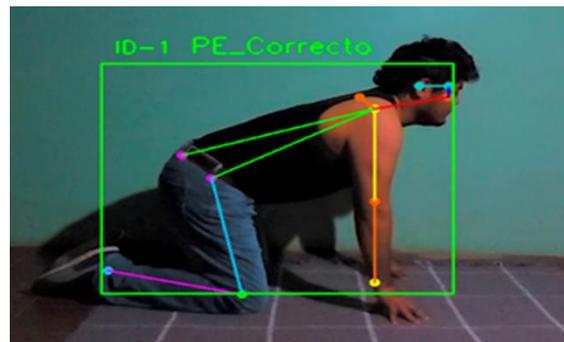


Figura 10. Resultado ejercicio PE reconocido correctamente

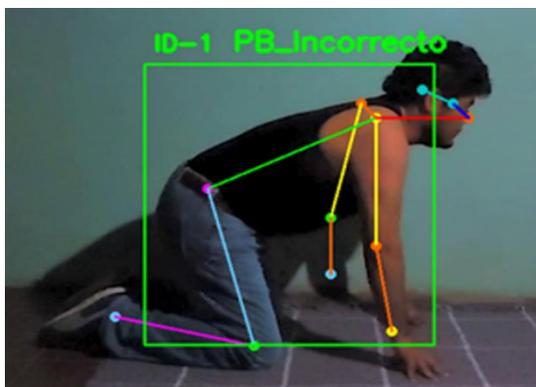


Figura 11. Resultado ejercicio PB reconocido incorrectamente

6 CONCLUSIONES

Este sistema es un instrumento funcional para la utilización en el área de la fisioterapia, ya que, por las diferentes pruebas realizadas, se observa una respuesta correcta por parte del sistema, dándonos diagnósticos aceptables de los ejercicios realizados, teniendo un margen de error bajo, por lo que por el momento se puede mencionar que los objetivos planteados se cumplieron satisfactoriamente, logrando tener un prototipo funcional con un porcentaje de exactitud del 97%, considerando aún las siguientes limitaciones: tener la cámara a un ángulo 90 grados y que el paciente se encuentre a una distancia de 2 metros de la cámara, por lo que se puede mencionar que se requiere aún de mucha información para el entrenamiento para optimizar el reconocimiento de los ejercicios de *Klapp* y poder evaluar el desempeño del modelo mediante alguna técnica como validación cruzada entre otros.

Otros factores a tener en cuenta son el uso de una *webcam* con resolución *HD* de 1280x720 pixeles, de igual forma si queremos que el sistema sea más preciso, el uso de *webcams* debe ser con una resolución mayor *FullHD* de 1920x1080 pixeles, *2K* de 2704x1524 pixeles o inclusive una *4K* de 3840x2160 pixeles, puede resultar más satisfactorio ya que permite una mejor reconocimiento del paciente y del entorno en el que se encuentra, obteniendo un resultado superior en los análisis de las rutinas. Además, en la ejecución de las rutinas el paciente debe estar en un entorno amplio y que no existan objetos que interfieran con el análisis de la rutina, como los barandales de las escaleras, manubrios de bicicletas, entre otros, pueden ser confundidos por el sistema como otra persona haciendo que los resultados que se obtengan de ese análisis sean erróneos.

Los resultados que el sistema reconoce son confiables, ya que los videos usados en el entrenamiento de la red neuronal recurrente fueron revisados y verificados en cada ejecución por los profesionales en el área de terapia fisioterapia de la UPAM.

Cabe señalar que el mejoramiento del sistema requiere de una mayor cantidad de datos para optimizar el funcionamiento y disminuir las limitaciones antes mencionadas.

7 TRABAJO FUTURO

Si hablamos de la precisión del modelo, ésta es buena; sin embargo, hacen falta datos de entrenamiento para obtener una mayor precisión en el proceso de reconocimiento de la pose del paciente, para que este no dependa de la posición de la cámara con un ángulo de 90 grados y mínimo a 2 metros de la cámara para que los puntos articulares sean detectados correctamente, siendo este un caso de estudio a futuro para mejorar el sistema.

Por otra parte, se trabajaría con los diferentes parámetros de la RNN para mejorar la exactitud en el reconocimiento y reducir el porcentaje de error. Así como también realizar comparaciones con otras variantes de la RNN como la LSTM y GRU y determinar cuál obtiene mejores resultados. Finalmente, se observó que las interfaces no son intuitivas, por lo que este sería otro trabajo a realizar para considerar los conceptos de usabilidad y accesibilidad en el sistema.

REFERENCIAS

- [1] Rabanales J., Párraga, I., López-Torres, J., Andrés, F., Navarro, B. *Tecnologías de la Información y las Comunicaciones: Telemedicina. REV CLÍN MED FAM*, 2011, 4 (1), 42-48. Disponible: <https://scielo.isciii.es/pdf/albacete/v4n1/especial1.pdf>.
- [2] Russell, S. J. *Inteligencia Artificial Un Enfoque Moderno (2.a ed.)*. Mexico: PRENTICE HALL/PEARSON, 2020
- [3] Ilktan y Akgul, Y. A Computerized Recognition System for the Home-Based Physiotherapy Exercises Using an RGBD Camera. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014.
- [4] Zurich, ETH. Recognition and Repetition Counting for Complex Physical Exercises with Deep Learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019.
- [5] Zhou, H., and Hu, H. Human motion tracking for rehabilitation-A survey. *Biomedical Signal Processing and Control*, 2008.
- [6] Moeslund, T.B., Hilton, A., y Kruger, V. A survey of advances in vision-based human motioncapture and analysis. *CVIU*, 2006.
- [7] Cáceres, JA. Método mezieres vs técnica de Klapp aplicada a estudiantes de entre 13 a 16 años con escoliosis idiopática en la unidad educativa Alberto Guerra del cantón cevallos en el período febrero – mayo 2015. Tesis Licenciatura. Universidad Técnica de Ambato, 2015. <http://repositorio.uta.edu.ec/bitstream/123456789/10367/1/C%20a1ceres%20Urrutia%20c%20Jessica%20Andrea.pdf>
- [8] Jinnovart, T., Cai, X. y Thonglek, K. Abnormal Gait Recognition in Real-Time using Recurrent Neural Networks. *59th IEEE Conference on Decision and Control (CDC)*, 2020, 972-977, doi: 10.1109/CDC42340.2020.9304106.
- [9] Alatah, T. y Chen, C. Recognizing Exercises and Counting Repetitions in Real Time. *CoRR, abs/2005.03194*, 2020. [En línea]. Disponible: <https://arxiv.org/abs/2005.03194>.
- [10] Jarrín, JL. Sistema de detección del ángulo articular en los movimientos de miembro superior para la evaluación en fisioterapia mediante visión artificial. *Trabajo de grado Ingeniería, Universidad Técnica del Norte, Ibarra-Ecuador*, 2020. [En línea]. Disponible: <http://repositorio.utm.edu.ec/handle/123456789/10295>.
- [11] Obaid, F., Babadi, A., y Yoosofan, A. Hand Gesture Recognition in Video Sequences Using Deep Convolutional and Recurrent Neural Networks. *Applied Computer Systems*, mayo 2020, 25(1), 57–61. [En línea]. Disponible: <https://doi.org/10.2478/acss-2020-0007>.
- [12] Leightley, L., Mukhopadhyay, S. C., Ghayvat, H. and Yap, M. H. Deep convolutional neural networks for motion instability identification using Kinect. *Fifteenth IAPR International Conference on Machine Vision Applications (MVA)*, 2017, 310-313, doi: 10.23919/MVA.2017.7986863.
- [13] Rodríguez, L. Telerehabilitación funcional en entornos virtuales interactivos como propuesta de rehabilitación en pacientes con discapacidad. *Espacios*, 2019, 40(5.5), 1, <https://www.revistaespacios.com/a19v40n25/a19v40n25p01.pdf>.
- [14] Barrios, M., Rodríguez, L., Pachón, C., Medina, B. y Sierra, JE. *Revista Espacios*, 2019, Vol. 40 (Nº 25). ISSN 0798 1015. <https://www.revistaespacios.com/a19v40n25/a19v40n25p01.pdf>.
- [15] Sierra J., Medina B., Rodríguez L. Desarrollo e implementación de tecnologías biomédicas para la telerehabilitación funcional. *Revista Colombiana de Tecnologías de Avanzada*, 2019. ISSN: 1692-7257 - Volumen 2 – Número 34.
- [16] Moreno, DL. *Inteligencia Computacional en Sistemas de Teleasistencia en Domicilios. Tesis doctoral. Universidad del País Vasco Euskal Herriko Unibertsitatea*, 2018. <https://core.ac.uk/download/pdf/168407281.pdf>.
- [17] Columna vertebral sana & Postura recta (3.3.5).2020.[Aplicación móvil]. App store. <https://play.google.com/store/apps/details?id=melstudi.o.mback>.
- [18] Ejercicios de dolor de espalda (1.0.82). 2020. [Aplicación móvil]. App store. <https://play.google.com/store/apps/details?id=com.vratsev.bpex>.
- [19] Ejercicios de Espalda en Casa (1.0). 2017. [Aplicación móvil]. App store. 65 <https://play.google.com/store/apps/details?id=com.doct.orapps>.
- [20] Mitchell, T. *Machine Learning (1ra. ed.)*. México: McGraw-Hill Education, 1997.
- [21] Goodfellow, I., Bengio, Y. y Courville, A. *Deep Learning*. MIT Press, 2016. Disponible: <https://www.deeplearningbook.org>.
- [22] Vaca, D. L. Una técnica de muestreo para categorizar videos. *RevActaNova. [en línea]*. 2018, 8(4), 631-650. ISSN 1683-0789.
- [23] Zumba, J. P. y León, C.A. Evolución de las Metodologías y Modelos utilizados en el Desarrollo de Software. *INNOVA Research Journal*, septiembre 2018, 3, 20-33.
- [24] Aguilera, A. A., & S. Gómez, O. Estudio de calidad y eficiencia de un enfoque de desarrollo software secuencial con programadores solos y en pareja. *SciELO*, Abril 2019. Disponible: https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-33052019000200304.
- [25] Martin, B., Bismarck et al. Enfoque actual en la rehabilitación de la escoliosis. *CCM [online]*. 2014, 18(1), 89-99.
- [26] Santoja, A. Higiene postural en el escolar. *Albacete:Editores Escolares Albacete*. 2012, <https://repositorio.uleam.edu.ec/bitstream/123456789/1673/1/ULEAM-FST-0035.pdf>.
- [27] Tribastone, F. *Compendio de Gimnasia Correctiva*. 3ed. Barcelona: Paidotribo, 2001.
- [27] Heaton, J. Introduction to Neural Networks for Java (2.a ed.). *Heaton Research, Inc*. 2008.

Acerca de los autores



Néstor Andrés García Rojas, estudiante de la carrera de Ingeniería en Software de la Universidad Politécnica de Amozoc en Puebla. Trabaja con tecnologías como HTML, PHP, JavaScript, Ajax, Django, C++, C#, C, Java, Kotlin, Swift, Python, MySQL, Unity, Unreal Engine, mismas que ha utilizado para los diferentes

proyectos realizados como son sistemas Web, aplicaciones móviles en Android y IOS, así como aplicaciones para los robots humanoide NAO y Darwin.

García tiene interés en el desarrollo de sistemas inteligentes enfocados al área de la salud y ha participado en proyectos de impacto que se han desarrollado mediante convenio con CONCYTEP.



Verónica Moreno Jiménez, obtuvo la Licenciatura en Ciencias de la Computación, Maestría en Administración en Tecnologías de la información. Ha ejercido por más de quince años en el área de desarrollo de software y en la coordinación de sistemas para diferentes empresas particulares. Se ha desempeñado como docente tanto presencial como en modalidad online desde hace más de 12 años, también realiza

trabajos de investigación dentro del área de sistemas, desarrollando aplicaciones con inteligencia artificial, realidad aumentada y programación con el Robot NAO, así mismo desarrollo móvil y web. Actualmente se desempeña como profesora de tiempo completo en la Universidad Politécnica de Amozoc (UPAM) en la ingeniería en software.



Rubelia Isaura Martínez Tellez, es Licenciada en Biomedicina, Mtra. Ciencias Fisiológicas y Master. En Estudios Médicos Biológicos, Nutrición y Homeopatía., Diplomada en Medicina Alternativas y Terapia Floral Sistema Bach, Elixires y Fitoterapia Mexicana.

Actualmente Profesora Tiempo Completo de la Licenciatura en Terapia Física en la Universidad

Politécnica de Amozoc con antigüedad de 9 años a la fecha. Cuenta con 15 años de experiencia en docencia e investigación. Responsable Acreditación CIEES y Evaluadora PRODEP. Certificada como Auditora Líder (ENLACE) e Instructora de Masaje Infantil (IAIM y REMI). Apoyos recibidos CONACYT, FUNIBER y PRODEP. 15 publicaciones científicas enfocadas en el área de las neurociencias, rehabilitación, biorrobótica y psicosocial. Integrante de Comité de Igualdad Laboral y No Discriminación y del Cuerpo Académico de la Licenciatura en Terapia Física. Presidenta de Academia de Ciencias Básica UPAM. Socia Fundadora Activa de Xiquita A.C. y grupos Culturales del CCU BUAP, IPJ, Casa del Abue DIF.



Gabriela Rabanales Gómez, realizó sus estudios de Licenciatura en Terapia Física en la Universidad Politécnica de Puebla, egreso en el año 2020. Realizó sus prácticas profesionales en el asilo José María de Yermo y Parres, en la clínica CEREFI y en el centro de la columna vertebral todos ubicados en el estado de Puebla. Se ha desempeñado en las técnicas de

punción seca y electrolisis.

Actualmente se encuentra realizando su servicio social en el cnetro médico Americano, como coordinadora en el área de rehabilitación, yc olabora en el cctentro de Equinoterapia la Villa en el municipio de Comalcalco, Tabasco.



Gudelia Pilar Pérez Conde, profesora-investigadora del Departamento de Tecnologías de la Información en la Universidad Politécnica de Puebla, Puebla, México. Recibió su grado de maestría en Ingeniería en Sistemas y Cómputo Inteligente por la Universidad Politécnica de

Puebla en el 2013, es miembro investigador de la red temática en Inteligencia Computacional Aplicada RedICA; sus áreas de interés son aprendizaje automático, minería de datos, visión artificial, ingeniería de software e Interacción humano-computadora con aplicaciones en medicina y educación.