



# Tecnológico Nacional de México

Centro Nacional de Investigación  
y Desarrollo Tecnológico

## Tesis de Maestría

Identificación de patrones atípicos en personas  
con movimientos involuntarios

presentada por

**Ing. Darien Calcedo Aguirre**

como requisito para la obtención del grado de  
**Maestro en Ciencias de la Computación**

Director de tesis

**Dr. Raúl Pinto Elías**

Cuernavaca, Morelos, México. Febrero de 2025.



Centro Nacional de Investigación y Desarrollo tecnológico  
Departamento de Ciencias Computacionales

Cuernavaca, Mor., **12/Febrero/2025**  
OFICIO No. DCC/046/2025

**Asunto:** Aceptación de documento de tesis  
CENIDET-AC-004-M14-OFICIO

**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**  
**PRESENTE**


Por este conducto, los integrantes de Comité Tutorial de **DARIEN CALCEDO AGUIRRE** con número de control M23CE051, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Identificación de patrones atípicos en personas con movimientos involuntarios"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

**ATENTAMENTE**

*Excelencia en Educación Tecnológica®*  
*"Conocimiento y Tecnología al Servicio de México"*

  
\_\_\_\_\_  
**Dr. Raúl Pinto Elías**  
Director de tesis

  
\_\_\_\_\_  
**Dra. Andrea Magadán Salzar**  
Revisor 1

  
\_\_\_\_\_  
**Dr. Nimrod González Franco**  
Revisor 2

Interior Internado Palmira S/N, Col. Palmira,  
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 3201,  
e-mail: dcc\_cenidet@tecnm.mx tecnm.mx | cenidet.tecnm.mx



**2025**  
Año de  
**La Mujer Indígena**





Centro Nacional de Investigación y Desarrollo tecnológico  
Subdirección Académica

Cuernavaca Mor, 19/febrero/2025

Oficio No. SAC/068/2025

Asunto: Autorización de impresión de tesis

**DARIEN CALCEDO AGUIRRE**  
**CANDIDATO AL GRADO DE MAESTRO**  
**EN CIENCIAS DE LA COMPUTACIÓN**  
**P R E S E N T E**

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"Identificación de patrones atípicos en personas con movimientos involuntarios"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

**A T E N T A M E N T E**


*Excelencia en Educación Tecnológica®*

*"Conocimiento y Tecnología al Servicio de México"*



**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**

c.c.p. Departamento de Ciencias Computacionales  
Departamento de Servicios Escolares



CMAZ/lmz



**2025**  
Año de  
**La Mujer**  
Indígena

Interior Internado Palmira S/N, Col. Palmira,  
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 4104,  
e-mail: acad\_cenidet@tecnm.mx tecnm.mx | cenidet.tecnm.mx

**cenidet**  
Centro Nacional de Investigación y Desarrollo Tecnológico



## **Dedicatorias**

*Esta tesis se las dedico a mis padres que desde el cielo me cuidan.*

*A Dios, por otorgarme la salud para empezar y concluir mi maestría.*

*A mi esposa, por su paciencia y mimos cuando no me salían algunas experimentaciones.*

*Al resto de mi familia en Cuba, por siempre tener una palabra de aliento.*

*A mí, por no rendirme y claudicar.*

*Mi logro es compartido con todos ellos*

## **Agradecimientos**

A la Secretaría de Ciencias, Humanidades, Tecnología e Innovación (SECIHTI) por la beca otorgada durante la realización de esta investigación.

A los investigadores, personal administrativo y técnicos del TecNM/CENIDET por su apoyo brindando las instalaciones de la institución.

A mi director de tesis el Dr. Raúl Pinto Elías, por su paciencia, asesoramiento y comentarios certeros que me ayudaron a terminar la maestría.

A los miembros del comité revisor, Dra. Andrea Magadán Salazar y Dr. Nimrod González Franco, por sus observaciones y comentarios realizados para mejorar dicha investigación.

A mis compañeros de generación y demás estudiantes de la línea de investigación, por sus ideas y sugerencias.

## Resumen

Los trastornos del movimiento son enfermedades neurológicas que afectan el control motor y pueden incluir afecciones como Parkinson, ataxia y nistagmo. Estos trastornos se caracterizan por síntomas como temblores, rigidez muscular y problemas de equilibrio, los cuales impactan negativamente la calidad de vida de quienes los padecen. La detección temprana es clave para ofrecer tratamientos más efectivos y mejorar el pronóstico.

La inteligencia artificial (IA) se presenta como una herramienta prometedora para la detección precoz de trastornos del movimiento. Mediante el análisis de datos clínicos, biomédicos (como EEG o EMG) y el uso de algoritmos de aprendizaje automático, la IA puede identificar patrones asociados a estos trastornos en sus etapas iniciales. Además, esta tecnología puede monitorizar la progresión de la enfermedad y evaluar la respuesta a los tratamientos, lo que permite personalizar las intervenciones.

La implementación de modelos de *machine learning* adecuados puede lograr una detección precisa de los síntomas y patrones motores anormales. El proceso implica el entrenamiento de algoritmos con datos etiquetados y la posterior evaluación de los resultados mediante métricas específicas. Estudios previos han demostrado que la IA puede identificar con alta precisión tanto los movimientos normales como los asociados a enfermedades neurológicas, lo que respalda su uso como herramienta clínica en este ámbito.

En esta investigación se propone un modelo para identificar patrones motores atípicos en personas con movimientos involuntarios, utilizando métodos no invasivos para el paciente. Se seleccionó la enfermedad de Parkinson como caso de estudio, enfocándose en dos tipos de movimientos: uno esperado, como el temblor postural en las manos, y otro atípico, la discinesia facial. Este último consiste en movimientos bruscos y descontrolados que suelen manifestarse en pacientes con varios años de tratamiento con levodopa, un fármaco comúnmente utilizado para tratar los síntomas clásicos del Parkinson.

El modelo desarrollado emplea visión por computadora para analizar videos y logró identificar con precisión tanto el temblor postural como la discinesia facial. En el caso del temblor, se alcanzaron y superaron las métricas reportadas en investigaciones previas, consolidando la efectividad del enfoque. Respecto a la discinesia facial, se lograron establecer métricas cuantificables, representando una contribución novedosa, ya que no se encontraron estudios previos que abordaran este fenómeno en el estado del arte. Este avance constituye el principal aporte de la investigación, abriendo nuevas posibilidades para el monitoreo y diagnóstico en pacientes con Parkinson.

## Abstract

Movement disorders are neurological diseases that affect motor control and may include conditions such as Parkinson's disease, ataxia, and essential tremor. These disorders are characterized by symptoms such as tremors, muscle rigidity, and balance issues, which significantly impact the quality of life of those affected. Early detection is key to providing more effective treatments and improving prognosis.

Artificial intelligence (AI) emerges as a promising tool for the early detection of movement disorders. Through the analysis of clinical and biomedical data (such as EEG or EMG) and the use of machine learning algorithms, AI can identify patterns associated with these disorders in their initial stages. Furthermore, this technology can monitor disease progression and evaluate treatment responses, enabling personalized interventions.

The implementation of suitable machine learning models can achieve accurate detection of symptoms and abnormal motor patterns. This process involves training algorithms with labeled data and subsequently evaluating the results using specific metrics. Previous studies have shown that AI can accurately identify both normal movements and those associated with neurological disorders, supporting its use as a clinical tool in this field.

This research proposes a model to identify atypical motor patterns in individuals with involuntary movements, using non-invasive methods for the patient. Parkinson's disease was selected as the case study, focusing on two types of movements: an expected one, such as postural tremor in the hands, and an atypical one, facial dyskinesia. The latter consists of abrupt and uncontrolled movements that typically manifest in patients after several years of treatment with levodopa, a drug commonly used to address the classical symptoms of Parkinson's disease.

The developed model uses computer vision to analyze videos and successfully identified both postural tremors and facial dyskinesia with high precision. For tremors, the metrics achieved matched and exceeded those reported in previous studies, validating the approach's effectiveness. For facial dyskinesia, quantifiable metrics were established, representing a novel contribution, as no prior studies addressing this phenomenon were found in the state of the art. This advancement constitutes the primary contribution of the research, opening new possibilities for monitoring and diagnosing Parkinson's disease patients.

# Índice

Lista de acrónimos .....	vi
1. Introducción .....	1
1.1 Marco conceptual .....	2
1.1.1. Movimiento voluntario .....	2
1.1.2. Movimiento involuntario típico .....	2
1.1.3. Trastorno del movimiento .....	2
1.1.4. Inteligencia Artificial .....	3
1.2. Antecedentes del proyecto .....	5
1.3. Estado del arte .....	6
1.4 Discusión .....	17
1.4.1 Brecha identificada .....	17
1.4.2 Justificación del enfoque propuesto .....	17
1.4.3 Relevancia clínica y social .....	17
1.4.4 Contribuciones metodológicas .....	17
1.4.5 Limitaciones y perspectivas futuras .....	18
2. Descripción del problema .....	19
2.1. Delimitación del problema específico .....	19
2.2. Complejidad del problema .....	19
2.3. Planteamiento de solución .....	20
2.4. Objetivos .....	20
2.4.1 Objetivo general .....	20
2.4.2 Objetivos específicos .....	20
2.5. Alcances y limitaciones .....	20
2.6. Justificación y beneficios .....	21
2.7. Propuesta de solución .....	21
3. Análisis, diseño e implementación del sistema .....	23
3.1 Arquitectura del sistema .....	23
3.1.1 Etapa de establecimiento de la ROI .....	24
3.1.2 Extracción de características .....	27
3.1.3 Preprocesamiento de los datos .....	28
3.2 Modelos de aprendizaje usados .....	29
3.2.1 Red CNN .....	29
3.2.2 Red LSTM .....	30
3.2.3 Perceptrón multicapa .....	30
3.3 Interfaz del sistema .....	31
4. Experimentación y análisis de resultados .....	38
4.1 Objetivos y alcances .....	38
4.2 Experimentación .....	38
4.2.1 Clasificación para la clase temblor .....	41
4.2.2 Clasificación para la clase discinesia .....	41



4.2.3 Clasificación para la clase sano.....	42
4.2.4 Experimentación en zona de manos.....	43
4.2.5 Experimentación en zona de rostro .....	44
4.3 Análisis de resultados.....	46
5. Conclusiones.....	52
5.1 Aportes .....	52
5.2 Trabajo futuro .....	53
Referencias .....	54
Anexos .....	58
Anexo A.....	58
Movimiento involuntario .....	58
Anexo B.....	60
Movimiento involuntario típico.....	60
Anexo C.....	61
Trastornos del Movimiento.....	61
Parkinson.....	61
Ataxia.....	63
Nistagmo.....	65
Anexo E.....	67
Red LSTM.....	67
Anexo F.....	70
Perceptrón multicapa.....	70
Anexo G .....	71
Constancias de participación .....	71

# Índice de figuras

<b>Figura 1.1</b> Aplicaciones de la Inteligencia Artificial (Iberdrola, 2023). .....	4
<b>Figura 2.1</b> Arquitectura del sistema. Fase de entrenamiento. ....	21
<b>Figura 2.2</b> Arquitectura del sistema. Fase de clasificación. ....	22
<b>Figura 3.1</b> Detección de landmarks de la mano. ....	25
<b>Figura 3.2</b> Landmarks originales obtenidas con el módulo face_landmarker_v2_with_blendshape. ....	25
<b>Figura 3.3</b> Landmarks de la zona de la boca usadas para el análisis de características. ....	26
<b>Figura 3.4</b> Región de las manos con temblores encerradas en un cuadro. ....	27
<b>Figura 3.5</b> Resultado de la importancia de las características. Las que más aportan al modelo son la 10 (disparidad en zona de la silueta facial), seguidas de la 4 (amplitud) y la 7 (disparidad en zona de los ojos). ....	28
<b>Figura 3.6</b> Resultado de la importancia de las características. En el caso de temblores, la característica 3 (frecuencia) es la más importante. ....	29
<b>Figura 3.7</b> Gráficas del entrenamiento y las métricas obtenidas con yolov8. ....	30
<b>Figura 3.8</b> Interfaz principal del sistema. ....	32
<b>Figura 3.9</b> Detección de manos con la webcam. Sujeto sano. ....	33
<b>Figura 3.10</b> Resultado de aplicar MLP al video. ....	34
<b>Figura 3.11</b> Persona con temblor del Parkinson. ....	35
<b>Figura 3.12</b> Resultado de aplicar Random Forest a un video nuevo. Paciente con temblores de Parkinson. ....	36
<b>Figura 3.13</b> Paciente con discinecia facial. ....	37
<b>Figura 3.14</b> Resultado obtenido luego de aplicar KNN. ....	37
<b>Figura A.1</b> Circuito de movimiento voluntario originado en el cerebro (Virameteeikul & Bhidayasiri, 2022). ....	59
<b>Figura C.1</b> Circuito de los ganglios basales y otras sustancias involucradas en el movimiento (Zhe Liu, 2017). ....	61
<b>Figura E.1</b> Arquitectura de la red LSTM, en ella se encuentra la celda de estado C, el estado oculto h, la entrada x, así como la salida o (Das et al., 2023) .....	67
<b>Figura G.1</b> Constancia de participación en el evento de inteligencia computacional y robótica, con poster relacionado con la investigación. ....	71

# Índice de tablas

<b>Tabla 1.1</b> Resumen del estado del arte. ....	12
<b>Tabla 4.1</b> Cantidad de videos usados para conformar los vectores de características, separados por clases. ....	39
<b>Tabla 4.2</b> Experimento 1. Comparación de resultados con clasificadores clásicos y red LSTM. ....	40
<b>Tabla 4.3</b> Métricas obtenidas con red LSTM y los 3 casos de estudio. ....	40
<b>Tabla 4.4</b> Experimento 2. Comparación de resultados con clasificadores clásicos y MLP. ....	41
<b>Tabla 4.5</b> Métricas obtenidas con los 4 algoritmos en un video con temblor de manos. ....	41
<b>Tabla 4.6</b> Métricas obtenidas con los 4 algoritmos en un video de persona con discinesia. ....	41
<b>Tabla 4.7</b> Métricas obtenidas con los 4 algoritmos en un video de persona sin discinesia. ....	42
<b>Tabla 4.8</b> Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica accuracy. ....	42
<b>Tabla 4.9</b> Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica precision. ....	42
<b>Tabla 4.10</b> Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica recall. ....	43
<b>Tabla 4.11</b> Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica f1-score. ....	43
<b>Tabla 4.12</b> Promedio de las métricas accuracy, precision, recall y f1_score para los algoritmos en todas las clases. Experimentación con 3 clases. ....	43
<b>Tabla 4.13</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica accuracy. ....	44
<b>Tabla 4.14</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica precision. ....	44
<b>Tabla 4.15</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica recall. ....	44
<b>Tabla 4.16</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica f1_score. ....	44
<b>Tabla 4.17</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica accuracy. ....	45
<b>Tabla 4.18</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica precision. ....	45
<b>Tabla 4.19</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica recall. ....	45
<b>Tabla 4.20</b> Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica f1_score. ....	45

<b>Tabla 4.21</b> Promedio de las métricas accuracy, precision, recall y f1_score para los algoritmos en todas las clases. Experimentación con 4 clases.....	46
<b>Tabla 4.22</b> Matriz de resultados de los experimentos vs objetivos.....	46
<b>Tabla 4.23</b> Matriz de resultados de los experimentos vs alcances.....	47

# Lista de acrónimos

<b>ANN</b>	<i>Artificial Neural Network</i>	Red neuronal artificial
<b>BACC</b>	<i>Balanced Accuracy</i>	Exactitud balanceada
<b>CAG</b>	<i>Cytosine Adenine Guanine</i>	Citosina Adeninina Guanina
<b>CNN</b>	<i>Convolutional Neural Network</i>	Red neuronal convolucional
<b>DNA</b>	<i>Deoxyribonucleic Acid</i>	Ácido desoxirribonucleico
<b>DRPLA</b>	<i>Dentatorubral Pallidoluysian Atrophy</i>	Atrofia dentato rubro pálido luisiana
<b>DT</b>	<i>Decision Tree</i>	Árbol de decisión
<b>EEG</b>	<i>Electroencephalography</i>	Electroencefalografía
<b>EMG</b>	<i>Electromyography</i>	Electromiografía
<b>FOG</b>	<i>Freezing of gait</i>	Congelamiento de la marcha
<b>GEN</b>	<i>Gaze-evoked nystagmus</i>	Nistagmo provocado por la mirada
<b>IA</b>	<i>Artificial Intelligence</i>	Inteligencia Artificial
<b>IMU</b>	<i>Inertial Measurement Unit</i>	Unidad de medición inercial
<b>NB</b>	<i>Naive Bayes</i>	Bayes ingenuo
<b>kNN</b>	<i>k-nearest neighbors</i>	<i>k</i> vecinos más cercanos
<b>LASSO</b>	<i>Least absolute shrinkage and selection operator</i>	Operador de mínima reducción absoluta y selección
<b>LDA</b>	<i>Latent Dirichlet Allocation</i>	Asignación latente de Dirichlet
<b>LRT</b>	<i>Logistic Regression Tree</i>	Árbol de regresión logística
<b>LSTM</b>	<i>Long Short Term Memory</i>	Redes de memoria a largo y corto plazo
<b>MLP</b>	<i>Multilayer perceptron</i>	Perceptrón multi capa
<b>PET</b>	<i>Positron Emission Tomography</i>	Tomografía por emisión de positrones
<b>PSP</b>	<i>Progressive Supranuclear Palsy</i>	Parálisis supranuclear progresiva
<b>PPCM</b>	<i>Parieto-Premotor-Primary Motor Cortex</i>	Circuito Parieto-Premotor-Corteza Motora-Primaria
<b>PT</b>	<i>Postural tremor</i>	Temblor postural

<b>RGB</b>	<i>Red, Green, Blue</i>	Rojo, verde y azul
<b>RF</b>	<i>Random Forest</i>	Bosque aleatorio
<b>RNA</b>	<i>Ribonucleic Acid</i>	Ácido ribonucleico
<b>SCAs</b>	<i>Spinocerebellar Ataxias</i>	Ataxias espinocerebelosas
<b>SCA2</b>	<i>Spinocerebellar Ataxias type 2</i>	Ataxias espinocerebelosas tipo 2
<b>SIN</b>	<i>Infantile Nystagmus Syndrome</i>	Síndrome de nistagmo infantil
<b>SMA</b>	<i>Supplementary Motor Area</i>	Área motora suplementaria
<b>SWJ</b>	<i>Square-wave jerks</i>	Sacudimientos en forma de onda cuadrada
<b>SVM</b>	<i>Support Vector Machine</i>	Máquina de vector soporte
<b>TDM</b>	<i>Movement Disorders.</i>	Trastornos del movimiento

# 1. Introducción

Los trastornos del movimiento son un grupo de enfermedades neurológicas que afectan la capacidad de una persona para controlar sus movimientos. Estos trastornos pueden incluir la enfermedad de Parkinson, la ataxia, el temblor esencial, la distonía y otros. Los síntomas pueden incluir temblores, rigidez muscular, lentitud de movimiento y problemas de equilibrio. A medida que estos trastornos progresan, pueden afectar la calidad de vida de las personas y limitar su capacidad para realizar actividades cotidianas.

La detección temprana de estos trastornos es esencial para un tratamiento efectivo y una mejor calidad de vida. La aplicación de la inteligencia artificial puede ser una herramienta valiosa para ayudar a detectar estos trastornos en fases tempranas y permitir una intervención. La inteligencia artificial puede procesar y analizar grandes cantidades de datos, lo que puede incluir información sobre los síntomas y la historia clínica del paciente, así como datos biomédicos como señales de Electroencefalografía (EEG) o Electromiografía (EMG).

Los algoritmos de aprendizaje automático pueden ser entrenados para detectar patrones específicos en estos datos, lo que puede ayudar a los profesionales médicos a identificar los trastornos del movimiento en etapas iniciales. La inteligencia artificial también puede ser utilizada para monitorear la progresión de los trastornos del movimiento y evaluar la efectividad del tratamiento. Esto puede ayudar a personalizar el tratamiento para cada paciente y optimizar los resultados del tratamiento.

Es posible mediante la inteligencia artificial establecer la detección de los síntomas típicos de los trastornos del movimiento con unos índices de acierto altos (Magesh et al., 2020). Dados estos hechos se infiere que también se pueden identificar patrones motores anormales o poco frecuentes para el grupo de enfermedades neurológicas que se analizarán en la investigación (Pfister et al., 2020). Para ello se sigue el mismo procedimiento que se ejecuta para identificar los movimientos comunes o normales para dichas enfermedades (Zhang et al., 2021). Se escoge un modelo de *machine learning* adecuado para resolver el problema en cuestión, se entrena a modelos de IA con un conjunto de datos previamente etiquetados y luego se evalúan los resultados con las métricas pertinentes (Williams et al., 2020).

En resumen, la aplicación de la inteligencia artificial en la detección en etapas iniciales de trastornos del movimiento puede mejorar la calidad de vida de las personas afectadas por estos trastornos y ayudar a los profesionales médicos a proporcionar una atención más efectiva y personalizada (Pfister et al., 2020).

## **1.1 Marco conceptual**

En esta sección se describen conceptos básicos para el desarrollo de esta tesis, con la finalidad de que el lector tenga una mejor comprensión. Se describirán conceptos como movimiento voluntario, movimiento involuntario típico (reflejo) así como los trastornos del movimiento. Además, se abordarán conceptos básicos relacionados con las ciencias computacionales como Inteligencia artificial (IA), visión por computador y algunas de las técnicas usadas en la IA para la detección de enfermedades.

### **1.1.1. Movimiento voluntario**

En las personas, el acto de realizar un movimiento es una actividad compleja en la que interviene un conjunto de sistemas como el nervioso, óseo y muscular. El aparato motor ha ido evolucionando a lo largo de la historia de los homínidos. Dentro de los patrones de movimiento, existen variaciones de acuerdo con los individuos. Estas se dan debido a las costumbres culturales, raza y otros aspectos. Incluso dentro de una misma cultura o raza, existen variaciones en los patrones de movimiento provocadas por la edad.

El movimiento voluntario es la ejecución intencionada de una acción, resultado de un proceso cognitivo. La voluntad de realizar un movimiento involucra a varios sistemas del cuerpo que interactúan de manera coordinada para lograr el objetivo. El proceso se origina en el sistema nervioso central, específicamente en los ganglios basales y el cerebelo, los cuales juegan un papel importante en la obtención de la variedad de los movimientos (Virameteeikul & Bhidayasiri, 2022). Las partes del cuerpo involucradas en la realización del movimiento voluntario se detallan en los anexos.

### **1.1.2. Movimiento involuntario típico**

Dentro del grupo de movimiento involuntario típico se puede catalogar a las acciones no visibles como el bombeo del corazón, la disminución o aumento de la frecuencia cardiaca y los movimientos intestinales. También existen otros movimientos involuntarios visibles como el acto de respirar, parpadear, dilatación de pupilas en condiciones de poca luminosidad y los reflejos. Estos últimos son una serie de respuestas motoras o secretoras ante estímulos determinados, pudiendo ser la persona consciente o no del movimiento que está realizando (Gordo et al., 2018).

### **1.1.3. Trastorno del movimiento**

Los trastornos del movimiento están compuestos por una serie de enfermedades neurológicas que afectan la capacidad de las personas para controlar los movimientos. Muchas de ellas son enfermedades degenerativas, haciendo que cada vez sea más difícil



para el individuo realizar tareas comunes, trayendo como consecuencia que se afecte la calidad de vida de las personas (Pfister et al., 2020). Estos trastornos pueden ser causados por lesiones en el cerebro, enfermedades genéticas o factores ambientales. Entre estas enfermedades se pueden mencionar al Parkinson, la ataxia, el nistagmo y la mioclonía (Belić et al., 2019) (Moscovich et al., 2015) (Newman et al., 2019). Estas enfermedades se detallan en los anexos.

Tras consultar diversas fuentes oficiales del gobierno mexicano, como por ejemplo el Instituto Nacional de Neurología y Neurocirugía "Manuel Velasco Suárez", se evidencia la imperante necesidad de dirigir un enfoque más acentuado hacia la enfermedad de Parkinson en el contexto mexicano. Se considera que la enfermedad se presenta de 150 a 200 casos por 100,000 habitantes por año en diversas partes del mundo; en México, 50 de cada 100,000 habitantes puede padecerla (Instituto Nacional de Neurología y Neurocirugía (INNN), 2017).

Aunque la ataxia también representa un desafío para el sistema de salud, su prevalencia es notoriamente menor en la población mexicana en comparación con el Parkinson. Esta última afección, más extendida entre los ciudadanos, requiere de una atención especializada y de estrategias de intervención más robustas. Reconocer la diferencia en la frecuencia de estas enfermedades es crucial para la asignación adecuada de recursos y la elaboración de programas de salud pública que respondan a las demandas reales de la sociedad.

#### **1.1.4. Inteligencia Artificial**

La inteligencia artificial es una rama de la ingeniería y la informática enfocada en la combinación de algoritmos elaborados con el propósito de crear máquinas que emulen capacidades similares que las del ser humano. Es decir, se plantea la posibilidad de crear máquinas que puedan "razonar", solucionar problemas, así como lograr un aprendizaje. El término fue mencionado por primera vez por el informático John McCarthy durante la conferencia del Dartmouth College, ubicado en Hanover, New Hampshire, en julio de 1956. Los expertos en ciencias de la computación Stuart Russell y Peter Norvig diferencian varios tipos de inteligencia artificial. Entre ellas se pueden destacar las siguientes:

- *Sistemas que piensan como humanos.* Automatizan actividades como la toma de decisiones, la resolución de problemas y el aprendizaje. Un ejemplo son las redes neuronales artificiales.
- *Sistemas que actúan como humanos.* Se trata de computadoras que realizan tareas de forma similar a como lo hacen las personas. Es el caso de los robots.
- *Sistemas que piensan racionalmente.* Intentan emular el pensamiento lógico

racional de los humanos, es decir, se investiga cómo lograr que las máquinas puedan percibir, razonar y actuar en consecuencia. Como ejemplo de este grupo están los sistemas expertos (Iberdrola, 2023).

Algunas de las técnicas de IA utilizadas en la actualidad incluyen la visión por computador, el procesamiento del lenguaje natural y el aprendizaje automático. Estas técnicas se emplean para mejorar la precisión y eficiencia en tareas que, de otro modo, requerirían la intervención de muchas personas o resultarían repetitivas para ellas. Además, dichas técnicas pueden analizar datos generados por herramientas como los sensores inerciales y las imágenes de resonancias magnéticas (MRI, por sus siglas en inglés), entre otras. La Figura 1.1 esboza algunas de las aplicaciones de la inteligencia artificial en la vida diaria.



Figura 1.1 Aplicaciones de la Inteligencia Artificial (Iberdrola, 2023).

#### **1.1.4.1. Visión por computadora**

Es una rama de la IA la cual consiste en sistemas informáticos que poseen la capacidad de analizar imágenes y videos para la interpretación y extracción de características o información relevante asociada a dichas imágenes. La capacidad de simular la visión humana a través de un sistema de percepción electrónico no es una tarea sencilla, ya que el ojo humano percibe la luz reflejada por los objetos en un espacio de tres dimensiones (3D), mientras que las computadoras analizan estos objetos a partir de proyecciones en imágenes de dos dimensiones (2D). La reducción de una dimensión produce la pérdida de gran cantidad de información, elevando la dificultad del proceso de visión. Las imágenes manejadas por las computadoras son bidimensionales debido a que el proceso de muestreo de la escena del mundo real se realiza, normalmente, a través de una rejilla rectangular, donde cada uno de sus elementos se conoce como píxel. Cada píxel puede almacenar valores de un tipo concreto, dependiendo del formato de representación de la imagen.

El uso de esta vertiente de la IA es aplicable a la agricultura, deporte, medicina entre otros, deduciéndose así que es útil para la detección de los Trastornos del Movimiento (TDM), analizando los patrones de movimientos de las personas. Por ejemplo, para identificar si un individuo presenta síntomas de Parkinson, la IA analiza la escritura a mano del paciente, ya que se ha comprobado que las personas con esta enfermedad presentan rasgos distintivos en la escritura.

### **1.2. Antecedentes del proyecto**

Dentro del CENIDET existen trabajos donde se ha abordado el tema de detección de regiones de interés en personas usando técnicas como visión por computador. En la investigación de (Gloria Vanessa Urquiza Flores, 2022) se logró la detección de anomalías en el comportamiento de una persona. Para ello, ocupó para la adquisición de datos, un sistema compuesto por 4 cámaras RGB (por sus siglas en inglés de los colores rojo, verde y azul) y sensores RFID (identificación por radiofrecuencia, por sus siglas en inglés) con acelerómetros y giroscopios que recopilaban información de la persona cuando estas no eran vistas por las cámaras.

En la investigación, se adquieren videos procedentes de 4 cámaras ubicadas en 4 lugares de una casa. En los videos, se realizó la detección de los objetos presentes. Posteriormente, se localizó a la persona bajo análisis (es decir, para la cual se comenzó a grabar y a adquirir los datos provenientes de los sensores). Se reportó, realizar la estimación de la pose humana y calcular la medida de proximidad de dicho sujeto a los

objetos de la habitación. Todas estas actividades fueron realizadas con el objetivo de reconocer las actividades diarias efectuadas por una persona.

Con la información adquirida, se construyeron grafos dirigidos que señalaban los patrones reconocidos de comportamiento de la persona monitoreada. Luego se hicieron máquinas de estados finitos que analizaban el patrón introducido para clasificarlo en normal o anormal. Como resultados en la experimentación del reconocimiento de actividades, los valores de exactitud más bajos fueron 85% y un idéntico 89% en las actividades de salir de casa (habitación-sala), leer periódico (misma habitación) y usar microondas (habitación-comedor). Los mayores valores se alcanzaron en las tareas de usar tocadador (habitación-dormitorio) y cocinar (habitación-cocina), en ambos casos con una exactitud de 95%.

El compañero de generación Héctor Panohaya Salcedo llevó a cabo una investigación titulada "Identificación de patrones de movimientos involuntarios (tics) en personas", la cual fue defendida con éxito en enero de 2025. Su estudio se enfocó en la zona del rostro, utilizando descriptores como las unidades de acción y el análisis de la simetría facial mediante similitud del coseno, distancias euclidianas y análisis de Procrustes.

Desarrolló dos modelos de clasificación:

- Modelo multiclase, con el que logró identificar 21 clases de interés con éxito.
- Modelo jerárquico, en el que clasificó tres clases principales y sus respectivas subclases.

Para su implementación, empleó clasificadores clásicos como KNN, SVM, DT, LR y RF, obteniendo los mejores resultados con el modelo jerárquico utilizando 20 atributos, alcanzando un 97% de *accuracy*, *precisión*, *recall* y *F1-score*.

### 1.3. Estado del arte

En la actualidad se emplean varias técnicas de IA para ayudar a establecer una detección temprana de los trastornos del movimiento como por ejemplo el Parkinson, la ataxia, el nistagmo, entre otros. Como datos de entrada se pueden analizar imágenes médicas como resonancias magnéticas, tomografías computarizadas, electroencefalogramas, entre otros. También se analizan videos, los datos emitidos por sensores inerciales portátiles, incluso la información ofrecida por teléfonos inteligentes con acelerómetros incorporados.

En (Tassew et al., 2022) se hace uso de redes neuronales convolucionales para diagnosticar pacientes de Parkinson dentro de 553 individuos, de los cuales 450 presentaban la enfermedad. Mediante esta técnica lograron el 98% de precisión con el algoritmo YOLO v7 analizando un *dataset* compuesto por imágenes de *DatScan*, así

como el 92% de precisión empleando imágenes de resonancia magnética.

En (Dostál et al., 2021) se recopilaron datos de 31 sensores colocados a lo largo del cuerpo de 25 personas, de ellos 12 sanos, para detectar síntomas de ataxia. Para ello emplearon algoritmos de *machine learning* tales como redes bayesianas, *k-Nearest Neighbours* y red neuronal convolucional (CNN por sus siglas en inglés) de 2 capas. Los parámetros de evaluación fueron exactitud, especificidad, sensibilidad y errores de validación cruzada. Se obtuvieron los mejores resultados en las redes neuronales, logrando el 77% de exactitud con los sensores ubicados en las piernas y pies, aumentando al 98% con los ubicados en los hombros, cabeza y espina dorsal. Por lo que se concluye que, los sensores ubicados en las extremidades superiores obtienen valores de métricas más altas mediante los algoritmos basados en redes neuronales.

En (Nunes et al., 2022) se usaron cintas de videos para distinguir a pacientes que presentaban sintomatología de Ataxia, de otros que tenían Parkinson y otros individuos sanos. Tomaron una muestra de 169 individuos con ataxia, 78 con Parkinson y 58 sanos. Como resultado se logró el 92% de acierto al diferenciar en la diferenciación de la ataxia *versus* individuos sanos, así como el 91% *versus* los pacientes con Parkinson. Se obtuvo el 68% al diferenciar los de Parkinson *versus* los sanos.

En (Belić et al., 2019) se aplicaron algoritmos de *machine learning* para la detección precisa y evaluación de pacientes con la enfermedad de Parkinson. Se emplearon algoritmos para, primero diagnosticar y luego monitorear y evaluar los síntomas típicos de la enfermedad como el temblor y la bradicinesia, así como los atípicos como la disquinesia. Para ello se usaron técnicas como visión por computadora y sensores inerciales en teléfonos inteligentes. Algunos de los algoritmos usados fueron: máquinas de vector soporte (SVM por sus siglas en inglés), *k* vecinos más cercanos (kNN), redes neuronales artificiales (ANN por sus siglas en inglés).

En esta investigación se usaron 300 personas como sujetos de prueba. Se evaluaron varios de los algoritmos con datos extraídos de las extremidades superiores e inferiores. Las extremidades superiores fueron evaluadas principalmente mediante teclados, smartphones y sensores inerciales, logrando valores de hasta 95% de exactitud en clasificación de temblores de pacientes con Parkinson comparados con sujetos sanos, usando *ensembles* de modelos de *machine learning*. Los valores de sensibilidad y especificidad fueron de 96% y 97% respectivamente. El algoritmo de Naïve Bayes (NB) alcanzó el 97% de precisión en la clasificación de la severidad del temblor. Las redes neuronales y las máquinas de vectores de soporte alcanzaron precisiones superiores al 90%.

Los estudios en piernas y pies se centraron en la marcha, la congelación de la marcha (FoG) y la estabilidad postural, usando sensores inerciales, cámaras de captura de

movimiento y dispositivos portátiles. Las SVM logró el 85% de precisión en la detección de Parkinson en fases tempranas basándose en parámetros cinemáticos de la marcha. El análisis de patrones de pisada con ANN alcanzó 96.4% de precisión al clasificar entre pacientes con Parkinson y controles sanos. Respecto al síntoma de FoG se detectaron con sensores inerciales en cintura y pies, alcanzando valores de 91% y 89% para las métricas de especificidad y sensibilidad respectivamente, utilizando SVM con *kernel* polinómico. Como conclusión de esa investigación se puede afirmar que las herramientas basadas en IA han demostrado alta eficiencia, pero es necesario mayor estandarización de protocolos y bases de datos para mejorar la aplicabilidad clínica.

En (Pfister et al., 2020) se usó *deep learning* para clasificar personas con Parkinson mediante los datos de movimiento. Se quería clasificar correctamente los estados de ON, OFF (presencia/ausencia), así como la disquinesia. Los algoritmos usados para llevar a cabo esta tarea fueron: *Random Forest*, kNN, SVM, Perceptrón multi capa (MLP) y las CNN. Además, para recolectar los datos se usaron sensores Unidad de medida inercial (IMU por sus siglas en inglés) colocados en la muñeca de los pacientes. Teniendo como muestra un total de 30 personas (20 hombres y 10 mujeres) con un promedio de edad de 67 años y con más de 10 años de diagnosticada la enfermedad.

Se obtuvieron los siguientes resultados, con las CNN se obtuvo el 67.39 % de precisión identificando las 3 fases, superando los valores alcanzados por los algoritmos SVM (50.28 %), kNN (50.41 %), *Random Forest* (53.73 %) y MLP (54.02 %). Además, la sensibilidad obtenida para las fases fue del 64 % en el estado OFF, del 66 % en el estado ON y del 64 % en la disquinesia. En cuanto a la especificidad, los valores registrados fueron del 89 %, 66 % y 89 % para los estados OFF, ON y disquinesia, respectivamente.

Como conclusión de este trabajo se obtiene que las redes neuronales convolucionales pueden ser de gran ayuda para la investigación ya que proporcionan resultados superiores al 60% analizando los datos recolectados por sensores con una muestra relativamente pequeña.

En (Trabassi et al., 2022) se trazó como objetivo determinar qué algoritmo de aprendizaje automático supervisado tiene mayor precisión al clasificar personas con Parkinson, emparejadas con sujetos sanos que tuvieran velocidad de la marcha similar. Se ocuparon los algoritmos de SVM, kNN, red neuronal artificial (ANN), DT y bosque aleatorio (RF por sus siglas en inglés). Además, se usaron sensores inerciales montados en la región lumbar para recolectar información de la marcha. Se tomó como muestra 64 personas con Parkinson idiopático (42 hombres y 22 mujeres) con un promedio de edad de 72 años. También se experimentó con 64 personas saludables, 31 hombres y 33 mujeres, con un promedio de 58 años.

Como resultado se obtuvo que, el SVM superó a otros algoritmos de aprendizaje automático en términos de métricas de clasificación (exactitud de prueba = 86%; puntuación F1 = 85%; AUC = 85%) y generalización (error de generalización = 2.95%).

Los algoritmos basados en árboles mostraron buenas métricas de clasificación con errores de generalización bajos (RF: exactitud de prueba = 86%; puntuación F1 = 85%; AUC = 85%) y menor demanda computacional que el SVM. ANN fue similar a DT en términos de métricas de clasificación, pero mostró un error de generalización significativamente mayor (7.26%) que los algoritmos basados en árboles y SVM, y una mayor demanda computacional que los otros algoritmos de aprendizaje automático. A pesar de que KNN mostró el rendimiento más rápido en términos de tiempo, sus métricas de clasificación fueron las más bajas.

En (María José Jiménez Aguilar, 2021) usan un trazador de imágenes PET (tomografía por emisión de positrones) para obtener una mejor precisión de diagnóstico, aplicando aprendizaje automático. Para ello se experimentó con 198 personas, 112 hombres y 86 mujeres, usando técnicas como SVM, RF, regresión logística, K-NN y ANN. Obteniendo un mejor resultado con las redes neuronales, teniendo el 99% en precisión, así como 98.67% en efectividad. Llegando así a la conclusión de que, las redes neuronales logran resultados mejores, que otros algoritmos, con muestras de mediano y gran tamaño.

En (Stoean et al., 2020) se aplicó el algoritmo de Monte Carlo para ayudar a la detección de la ataxia espinocerebelosa tipo 2. Para ello se usaron señales de electrooculograma como método de adquisición de información. A los datos recopilados se les aplicó *deep learning* a través de una red convolucional de 2 capas y 128 filtros, así como el algoritmo DT. Como conjunto de datos, utilizaron información de 513 personas: 172 presintomáticas, 172 enfermas y 169 sanas. Se obtuvo el 81.18 % de efectividad, así como el 81.9% en la precisión, luego de aplicar el algoritmo 500 veces. Además, se obtuvo el 94.12% de efectividad con los *test* efectuados con el DT.

En la investigación de (Carissimo et al., 2022) se implementó un software simulador del síntoma de temblor esencial presente en el Parkinson. El objetivo fue clasificar los 3 tipos esenciales de temblores existentes. Para ello usaron datos recopilados por sensores inerciales con acelerómetros y giroscopios, así como el algoritmo *fine tree* para el entrenamiento y clasificación. Como resultado de la investigación, se clasificaron los movimientos en ausencia de temblor, temblor en reposo, temblor postural y temblor cinético. Al combinar los datos de aceleración y de velocidad angular obtuvieron el 99.31%, 99.70% y 99.47% en las métricas de *precision*, *recall* y *f1 score* para la clasificación de temblor postural y en reposo.

Para el entrenamiento se usaron sensores con una resolución de 16 bits, mientras que para la fase de prueba se usaron otros con la mitad de la resolución. Según los datos reportados, los autores no aconsejan tener un conjunto de datos desiguales para las fases de entrenamiento y prueba, ya que degrada considerablemente el rendimiento.

En el trabajo de (Kim et al., 2022) se trazó el objetivo de discriminar los síntomas típicos de Parkinson (PD) de otros como la parálisis supranuclear progresiva (PSP), la atrofia multisistema parkinsoniana (MSA-P) y la atrofia multisistema cerebral (MSA-C). Para

adquirir la información se emplearon imágenes de resonancia magnética (MRI, concretamente del tipo T1 ponderada, T1w por sus siglas en inglés), así como imágenes de susceptibilidad ponderadas (SWI). A todas ellas se les hizo una refinación de contraste híbrido (HC). Además, se emplearon técnicas de *machine learning* como SVM, KNN, ADA Boost, RF, NN.

Los datos se recopilaron de 21 pacientes con MSA-C, 34 con MSA-P, 17 con PSP y 56 con PD. Se usaron las métricas de precisión balanceada (*bacc* por sus siglas en inglés), especificidad y sensibilidad. Con el algoritmo de SVM se obtuvo el 76.66% de *bacc* para el entrenamiento y el 79.9% para las pruebas usando la combinación de T1w y HC vs 65% de *bacc* para el entrenamiento y 76% para prueba, usando sólo las T1w. De forma general, siempre se obtuvo mejores resultados aplicando las técnicas combinadas para cada métrica.

En su investigación, (Zeng et al., 2019) reporta que su propósito era investigar la variabilidad del patrón de marcha representado por las señales verticales de un generador de radio frecuencias, que se asocia con pacientes con la enfermedad de Parkinson y compararlos con sujetos sanos. Se usaron 8 sensores inerciales ubicados en la plantilla de los pies, de una muestra de 93 pacientes con Parkinson y 73 saludables. Luego de realizar validación cruzada durante 10 veces, obtuvieron el 98.92%, 98.63%, 98.80 y 97.60% para las métricas de sensibilidad, especificidad, precisión y coeficiente de correlación de Mathews respectivamente.

Esos resultados fueron superiores a los encontrados en el estado del arte por el autor. Luego de analizar esta investigación, se puede decir que las validaciones cruzadas permiten obtener una fiabilidad alta de la medida de entrenamiento que posee un algoritmo. Es decir, mientras más validaciones de realicen, las reglas inferidas proporcionan un modelo mejor entrenado.

En el trabajo de (Chang et al., 2020) reporta que el objetivo era detectar anomalías en los movimientos oculares. Para ello se usaron videos captados por la cámara de un *iphone 8 plus* y de un *ipad pro*. Para clasificar ocuparon el SVM. Los datos recopilados por los dispositivos fueron extraídos de una muestra de 102 pacientes con ataxia, 43 con Parkinson y 18 sanos. Luego de entrenar el modelo con 28 características, para distinguir a los participantes con persecución sacádica (86) de los típicos (65) y combinar características, se obtuvo el mejor resultado con un área bajo la curva (AUC) de 85%, una sensibilidad de 84% y especificidad de 77%. Al diferenciar los participantes con ataxia de los sanos y de los que presentaban Parkinson, se obtuvo para el AUC el 72%, para la sensibilidad el 78% y una especificidad de 53%.

Como conclusión de esta investigación, se puede afirmar que la aplicación de SVM sobre un conjunto de datos adquiridos a través de videos de dispositivos móviles resulta útil para la clasificación de anomalías oculares. Sin embargo, es importante destacar que los resultados obtenidos no son altamente precisos, ya que las métricas no alcanzan valores



superiores al 90 %, lo que refleja ciertas limitaciones en la exactitud del modelo.

En el trabajo de (Newman et al., 2019) se planteó la posibilidad de detectar el nistagmo inducido en los individuos, usando un dispositivo CAVA (Continuous Ambulatory Vestibular Assessment). Para ello se usaron 5 sensores para la detección del nistagmo horizontal. Se aplicó el SVM y el *Ensemble classifier* of boosted tree (árbol reforzado para mejorar la precisión). La muestra se integró de 17 individuos adultos. Se logró el 98.8% de efectividad en la detección del nistagmo horizontal.

En la investigación de (Liu et al., 2023) se tenía como objetivo estimar el puntaje MDS-UPDRS (Movement Disorder Society-Unified Parkinson's Disease Rating Scale) de los temblores de la enfermedad de Parkinson basados solamente en video. Para recopilar los datos se usó una cámara Sony con una resolución de 1920×1280 que grababa a 30 *fps*. La muestra para los ensayos estuvo conformada por 130 pacientes con Parkinson. Como resultados, se obtuvo una precisión del 90.6% para manos con temblores en reposo, del 85.9% para temblores en la pierna, y del 89.0% para la mandíbula. Se obtuvo una precisión del 84.9% para los temblores posturales. Como conclusión de esa investigación, se comprobó que es posible la evaluación de los temblores característicos del Parkinson usando solamente la visión por computador.

En resumen, se revisaron los documentos más relevantes del estado del arte para analizar las tendencias en la aplicación de la inteligencia artificial (IA) en el ámbito de la medicina, con un enfoque particular en los trastornos del movimiento. Las principales enfermedades abordadas fueron el Parkinson, la ataxia y el nistagmo.

En los estudios analizados, se utilizaron diversas técnicas y herramientas de IA para identificar síntomas característicos de estas condiciones médicas. Sin embargo, no se encontraron detalles sobre la identificación de sintomatología atípica en los casos estudiados. A continuación, se detallan los artículos leídos en la Tabla 1.1.

Tabla 1.1 Resumen del estado del arte.

Título	Propósito	Técnicas de IA usadas	Tamaño de la muestra	Resultados obtenidos	Opinión de persona experta	Relevancia para la investigación
(Tassew et al., 2022)	Detectar la enfermedad de Parkinson.	MRI, así como imágenes DatScan y Yolo v7	450 pacientes con Parkinson temprano, 103 individuos sanos.	98% de exactitud con <i>DatScan</i> y 92% de precisión usando las MRI.	No	Verificación del funcionamiento del algoritmo yoloV7 en las redes neuronales convolucionales.
(Nunes et al., 2022)	Distinguir pacientes con Ataxia, parkinsonismo y personas sanas.	Se usó visión por computadora, así como deep learning.	169 personas con ataxia, 78 con parkinsonismo y 58 sanos.	92% de precisión al diferenciar ataxia vs sanos, 91% vs pacientes con Parkinson y 68% al diferenciar Parkinson vs sanos	Sí	El estudio aplica aprendizaje automático a videos de tapping de dedos, logrando una clasificación precisa de la ataxia.
(Dostál et al., 2021)	Detectar síntomas de ataxia	31 sensores y se aplicaron técnicas como redes bayesianas, kNN y CNN de 2 capas.	13 individuos sanos y 12 con ataxia	77% de exactitud con sensores ubicados en las piernas y pies, 98% con los ubicados en los hombros, cabeza y espina dorsal.	No	En los sensores ubicados en las extremidades superiores se obtuvieron métricas altas mediante las redes neuronales convolucionales.
(Stoean et al., 2020)	Aplicar el algoritmo de Monte Carlo para ayudar a la detección de la ataxia tipo 2	Se empleó una CNN de 2 capas y 128 filtros, así como el DT	172 personas presintomáticas, 172 enfermas y 169 sanas.	81.18 % de efectividad, así como el 81.9% en la precisión, 94.12% en la efectividad de los test efectuados con el DT.	No	Mejora en la precisión facilita la detección temprana de dicha condición médica.

Tabla 1.1 Resumen del estado del arte. (Continuación)

Título	Propósito	Técnicas de IA usadas	Tamaño de la muestra	Resultados obtenidos	Opinión de persona experta	Relevancia para la investigación
(María José Jiménez Aguilar, 2021)	Obtener una mejor precisión de diagnóstico de Parkinson	Trazador de imágenes PET, SVM, RF, LR, K-NN y CNN.	204 personas, 112 hombres y 86 mujeres	CNN, 99% en precisión, así como 98.67% en efectividad	Sí	En las muestras de mediano y gran tamaño las CNN aportan resultados mejores que otros algoritmos de entrenamiento.
(Newman et al., 2019)	Detectar el nistagmo inducido en los individuos	5 sensores, SVM	17 personas adultas y saludables	Se obtuvo el 98.8% de efectividad en la detección del nistagmo horizontal.	Sí	Sistema portátil que permite la evaluación continua fuera de ambiente clínico
(Belic et al., 2019)	Detección precisa y evaluación de pacientes con la enfermedad de Parkinson.	Visión por computadora, sensores inerciales en teléfonos inteligentes, SVM k-NN, Artificial Neural Networks	300 personas	El AdaBoost DT mostró una precisión del 86%. LDA, NB, kNN, SVM (linear), SVM (no linear) y DT lograron una precisión en el rango del 79.62% al 84.1%.	No se especifica	Algoritmos de <i>machine learning</i> , combinados con sensores accesibles, permiten diagnósticos precisos y monitoreo eficiente de la enfermedad
(Trabassi et al., 2022)	Determinar que algoritmo de aprendizaje automático tiene mayor precisión en la clasificación del Parkinson.	Sensores inerciales en la región lumbar. SVM, kNN, Artificial Neural, DT y RF.	64 personas con Parkinson idiopático y 64 individuos sanos	SVM (exactitud de prueba = 86%; puntuación F1 = 85%; AUC = 85%) y generalización (error de generalización = 2,95%).	Sí	Demuestra cómo ML con datos IMU mejora la precisión en el análisis de marcha en Parkinson, optimizando la selección de características.
(Pfister et al., 2020)	Clasificar los datos de movimientos en personas con Parkinson para distinguir los estados de ON, OFF y disquinesia.	Sensores IMU colocados en la muñeca. RF, kNN, SVM, MLP y las CNN.	30 personas, 20 hombres y 10 mujeres con más de 10 años de diagnosticada la enfermedad.	CNN, 67.39 % de precisión, 64% de sensibilidad para el estado de OFF, 66% para el ON y 64% para la disquinesia	Sí	Las CNN proporcionan resultados muy buenos analizando los datos recolectados por sensores.

**Tabla 1.1** Resumen del estado del arte. (Continuación)

Título	Propósito	Técnicas de IA usadas	Tamaño de la muestra	Resultados obtenidos	Opinión de persona experta	Relevancia para la investigación
(Carissimo et al., 2022)	Clasificar los 3 tipos esenciales de temblores existentes.	Sensores inerciales con acelerómetros y giroscopios, así como el algoritmo fine tree.	No especificado	Precisión de 99.31%, recall de 99.70% y f1 score de 99.47% en la clasificación de temblor postural y en reposo.	No	Tener un conjunto de datos desiguales para las fases de entrenamiento y prueba, degrada considerablemente el rendimiento.
(Kim et al., 2022)	Diferenciar síntomas típicos de Parkinson de otros como la parálisis supranuclear progresiva (PSP)	MRI, así como imágenes de susceptibilidad ponderadas (SWI)	56 pacientes con Parkinson, 17 con PSP y 55 con atrofias.	Precisión balanceada (bacc) de 76.66% en entrenamiento y 79.9% en pruebas.	Sí	Emplea patrones de hierro cerebral en imágenes ponderadas para diferenciar síndromes parkinsonianos atípicos, otorgando un diagnóstico más preciso.
(Zeng et al., 2019)	Investigar la variabilidad del patrón de marcha en pacientes con Parkinson.	8 sensores inerciales ubicados en la plantilla de los pies.	93 pacientes con Parkinson y 73 saludables	98.92%, 98.63%, 98.8% y 97.6% para las métricas de sensibilidad, especificidad, precisión y coeficiente de correlación de Mathews respectivamente.	Sí	Las validaciones cruzadas mejoran la fiabilidad del entrenamiento de un algoritmo, obteniéndose un modelo mejor entrenado con reglas inferidas.
(Chang et al., 2020)	Detectar anomalías en los movimientos oculares	Videos de cámara de un iphone 8 plus y de un ipad pro. SVM	102 pacientes con ataxia, 43 con Parkinson y 18 sanos	Área bajo la curva (AUC) de 85%, una sensibilidad de 84% y especificidad de 77% al diferenciar los participantes con ataxia de los sanos.	Sí	La aplicación de SVM sobre un conjunto de datos adquiridos a través de videos de dispositivos móviles es útil para clasificar anomalías oculares pero los resultados no son tan exactos.

**Tabla 1.1** Resumen del estado del arte. (Continuación)

Título	Propósito	Técnicas de IA usadas	Tamaño de la muestra	Resultados obtenidos	Opinión de persona experta	Relevancia para la investigación
(Liu et al., 2023)	Estimar el puntaje MDS-UPDRS de los temblores de la enfermedad basados en video.	Cámara Sony con una resolución de 1920×1280 que grababa a 30 fps.	130 pacientes	Precisiones de 90.6% para temblores en manos en reposo, 85.9% para temblores en piernas, 89.0% para temblores en la mandíbula, y 84.9% para temblores posturales.	Si	Es posible la evaluación de los temblores característicos del Parkinson usando solamente la visión por computador.
(Borzi et al., 2023)	Detectar episodios de congelamiento de la marcha en personas con Parkinson durante las actividades de la vida diaria.	Se usó un único sensor inercial puesto en diferentes partes del cuerpo	118 pacientes de Parkinson y 21 individuos saludables	Sensor ubicado en la cintura, 91% y 89% para sensibilidad y especificidad respectivamente.	No se especifica	Se obtuvieron buenos resultados a pesar de solo usar un sensor inercial. Gracias al uso de la CNN multicapa. Se obtuvo una baja latencia en el tiempo de detección y bajo consumo de memoria.
(Williams et al., 2020)	Detectar la bradicinesia en personas con Parkinson usando videos tomados por smartphones	Se usó para grabar los videos un iPhone SE con una resolución de 1920 x1080 y a 60 fps. Buen ambiente de iluminación.	70 videos de manos de personas, 40 con Parkinson y 35 sanas.	SVM-R, idéntico 84% para exactitud y AUC en el entrenamiento. Para las pruebas alcanzaron un 80%, 86% y 74% para las métricas de exactitud, sensibilidad y especificidad	Sí	La técnica de flujo óptico es útil para analizar el movimiento de las manos cuadro a cuadro.

Tabla 1.1 Resumen del estado del arte. (Final)

Título	Propósito	Técnicas de IA usadas	Tamaño de la muestra	Resultados obtenidos	Opinión de persona experta	Relevancia para la investigación
(Ronnachai Jaroensri, 2017)	Cuantificar la gravedad del deterioro del movimiento en pacientes con Ataxia usando la escala BARS.	Videos monoculares propios, otras imágenes de Internet. Técnica LASSO y una CNN	90 videos de 43 personas, 15 sanas.	0.34% de error absoluto, inferior al que se había alcanzado a través de la clasificación de un experto en la materia (0.37%).	Sí	Presenta un método automatizado basado en video para evaluar la severidad de la ataxia, utilizando estimación de pose y flujo óptico.
(Zhang et al., 2021)	Evaluar de forma automática las anomalías posturales en personas con Parkinson	Cámara de profundidad Kinect v2.0 con resolución 1920 x 1080 y grabación a 30 fps. Otra cámara con resolución 512 x 424 grabando a 30 fps. DT, kNN y SVM.	70 personas con Parkinson	Se obtuvo un 90% de exactitud, 95.7% de especificidad y 89% de sensibilidad después de aplicar 5 veces una validación cruzada para el DT	Sí	Un sistema basado en Kinect y machine learning puede evaluar automáticamente anomalías posturales en pacientes con Parkinson con alta precisión y consistencia clínica.
(Magesh et al., 2020)	Detectar el Parkinson en personas que tuvieran al menos 2 años con el padecimiento	Imagen funcional de tomografía computarizada por emisión monofotónica (SPETC). CNN VGG16	212 personas saludables y 430 individuos con Parkinson. Todos mayores de 30 años.	Se obtuvo un 95.2% de precisión, un 97.5% de sensibilidad y una especificidad de 90.9%	No se especifica	El modelo utiliza LIME para justificar la detección temprana de Parkinson en imágenes DaTSCAN, mejorando la confianza en el diagnóstico asistido por IA.
(Giovanni D'Addio et al., 2019)	Identificar algunas características del nistagmo usando algoritmos de aprendizaje automático	Algoritmos de random forest y logistic regression tree	20 personas, 10 mujeres y 10 hombres con edades que oscilaban entre 6 y 34 años	Coefficiente para la agudeza visual de 85% y de 73% para la variabilidad de la posición de los ojos, con RF. Con el LRT se obtuvo un 72% y 70% para las mismas características. Con el RF para medir la agudeza visual no se detectó error alguno.	No se especifica	Aplicar <i>machine learning</i> para predecir parámetros clínicos claves del nistagmo congénito, mejora el diagnóstico de dicha enfermedad.

## **1.4 Discusión**

La revisión del estado del arte presentada en la sección 1.3 ha permitido identificar avances significativos en la aplicación de la inteligencia artificial (IA) para la detección y monitoreo de trastornos del movimiento, especialmente en condiciones como el Parkinson, la ataxia y el nistagmo. Sin embargo, también ha puesto de manifiesto una importante brecha que justifican la necesidad de esta investigación.

### **1.4.1 Brecha identificada**

Uno de los principales vacíos en la literatura es la ausencia de estudios que se enfoquen en la identificación de discinesias, un fenómeno motor atípico que afecta significativamente la calidad de vida de los pacientes con Parkinson en etapas avanzadas de la enfermedad. Aunque se han desarrollado modelos para la detección de movimientos típicos asociados a este trastorno, como temblores posturales y en reposo, ningún trabajo previo ha reportado la aplicación de técnicas de IA para analizar y clasificar las discinesias faciales.

### **1.4.2 Justificación del enfoque propuesto**

Ante esta brecha, esta investigación se propone como un esfuerzo pionero al desarrollar un modelo basado en IA que pueda identificar patrones motores atípicos, con un énfasis especial en la discinesia facial. La elección de este enfoque responde no solo a la falta de estudios existentes, sino también a la necesidad clínica de herramientas no invasivas que permitan una detección temprana y precisa. Este método, al utilizar visión por computadora para analizar videos, elimina la necesidad de sensores portátiles o pruebas médicas invasivas, mejorando la comodidad y la aceptación por parte de los usuarios.

### **1.4.3 Relevancia clínica y social**

El desarrollo de una herramienta de estas características podría tener un impacto significativo en la práctica clínica. La detección temprana de patrones atípicos como las discinesias podría facilitar ajustes más oportunos en el tratamiento farmacológico, optimizando la calidad de vida de los pacientes y reduciendo complicaciones. Además, la naturaleza no invasiva del método propuesto lo convierte en una opción accesible tanto para entornos clínicos como para el monitoreo domiciliario, promoviendo la equidad en el acceso a soluciones tecnológicas.

### **1.4.4 Contribuciones metodológicas**

En cuanto al diseño metodológico, el modelo propuesto emplea algoritmos de aprendizaje supervisado para analizar datos visuales y características de movimiento extraídas de secuencias de video. Esto permite diferenciar los movimientos típicos de los atípicos mediante un enfoque novedoso que integra técnicas como la transformada discreta del coseno y el análisis de Procrustes. Estas herramientas, aplicadas al área facial, representan una contribución única que no ha sido explorada previamente en estudios similares, dentro de toda la literatura consultada.

### **1.4.5 Limitaciones y perspectivas futuras**

A pesar de sus fortalezas, el modelo también enfrenta limitaciones inherentes a su enfoque. La dependencia de *datasets* obtenidos de plataformas como *YouTube* introduce variabilidad en la calidad de los datos, lo que podría influir en los resultados. Además, el sistema no opera en tiempo real, lo que limita su aplicabilidad en situaciones clínicas urgentes. Futuras investigaciones podrán enfocarse en:

- Desarrollar modelos que permitan la detección en tiempo real.
- Ampliar los *datasets* mediante colaboraciones con instituciones clínicas para garantizar mayor representatividad.
- Validar el modelo en un entorno clínico real con una muestra mayor de pacientes.

En conclusión, esta investigación se posiciona como un avance significativo en la aplicación de IA para el análisis de movimientos atípicos, particularmente en el caso de las discinesias. Su enfoque no invasivo y su potencial impacto clínico y social subrayan la relevancia y novedad de la propuesta.



## 2. Descripción del problema

El objeto de estudio en la investigación son los movimientos humanos. Los mismos pueden ser clasificados en voluntarios e involuntarios. Dentro de los involuntarios, existe un grupo que es considerado normal (respirar, parpadear) y otro que contempla a los movimientos que pueden ser a causa de una condición médica. Este último grupo suele presentar una serie de síntomas o movimientos que se consideran estereotipados, los cuales suelen ocurrir con una frecuencia bastante alta (Héctor A. González-Usigli, 2022). Pero en ocasiones se observa en personas, que dichos patrones de movimiento sufren alteraciones, cambia la intensidad del movimiento esperado y, por consiguiente, ocurre una variabilidad en la sintomatología.

Este cambio es importante tenerlo en cuenta porque puede ser precursor de una enfermedad constituyente en trastorno del movimiento o que un individuo ya diagnosticado con una enfermedad esté a punto de experimentar un deterioro en su condición médica, por lo que sería necesaria la intervención del especialista médico que realizara un reconocimiento y posterior evaluación del tratamiento a seguir.

Muchos de estos cambios en el movimiento se asemejan a lo que se espera que sea un patrón típico de comportamiento para el trastorno, provocando que sea difícil establecer una identificación de dichos patrones atípicos. A las personas que presenten este tipo de movimiento se les llamará *sujetos de interés* en la presente investigación. Debido a lo anteriormente expuesto se plantea el siguiente problema:

### 2.1. Delimitación del problema específico

Diferenciar dentro del grupo de movimientos involuntarios, los patrones típicos de los atípicos en los *sujetos de interés*.

### 2.2. Complejidad del problema

Dada la naturaleza del movimiento en las personas, es muy común encontrar patrones motores involuntarios semejantes a los voluntarios. Cabe destacar que la persona también puede realizar movimientos que son considerados como tics, dificultando aún más su correcta clasificación. En la literatura consultada, se reportan solamente los patrones típicos dentro de los TDM (Borzi et al., 2023; Chang et al., 2020). Hasta la fecha, no se conoce un trabajo previo donde se haya abordado el tema de los patrones de movimientos atípicos presentes en la enfermedad del Parkinson.

## 2.3. Planteamiento de solución

Dada la problemática planteada anteriormente (sección 2.1), se propone implementar un modelo de aprendizaje supervisado que analice datos cambiantes en el tiempo de características asociadas a movimientos involuntarios en las personas, modelando los patrones de movimiento típicos, para diferenciarlos de los movimientos atípicos y detectar dichas anomalías.

## 2.4. Objetivos

### 2.4.1 Objetivo general

Determinar las características asociadas a los movimientos involuntarios.

### 2.4.2 Objetivos específicos

- Seleccionar un tipo de movimiento involuntario, aplicar técnicas de Inteligencia Artificial para modelar y reconocer los patrones de movimientos “típicos” y detectar los movimientos atípicos que pudieran ser dañinos.
- Adquirir datos visuales referentes a los movimientos en personas.

## 2.5. Alcances y limitaciones

### Alcances

- Se realiza la identificación de los patrones analizando imágenes de una persona a la vez.
- El sistema es capaz de identificar patrones de movimientos involuntarios en cualquier persona.
- Se modelan algoritmos que realicen parte del trabajo. Una de esas tareas consiste en la localización de personas dentro de un ambiente controlado.
- Escoger un modelo de *machine learning* para que aprenda a identificar al menos un patrón típico dentro de los TDM.
- Se reconoce al menos un movimiento anormal dentro de los TDM con respecto al comportamiento de los movimientos aprendidos.
- Se realiza el entrenamiento y prueba con conjunto de datos adquiridos a través de visión por computadora o cámaras RGB con profundidad.

## Limitaciones

- La detección no se realiza en tiempo real.
- Los movimientos de interés para la investigación son los involuntarios típicos y atípicos.

## 2.6. Justificación y beneficios

Desde el enfoque clínico, es un objetivo lograr la identificación temprana de una posible condición médica contando con un número mínimo de recursos (Williams et al., 2020) . También es de sumo interés brindar monitoreo a personas que ya fueron diagnosticadas con algún desorden del movimiento. De esta manera se contribuye al seguimiento de la enfermedad para su evaluación, tanto en etapas iniciales como en avanzadas (Magesh et al., 2020).

## 2.7. Propuesta de solución

Para abordar el problema planteado, se propuso una herramienta que analice secuencias de video, extrayendo cada una de las imágenes individuales para su preparación y análisis. En cada imagen, se localiza la región relevante y se extraen las características clave del movimiento. Luego, se evalúa el tipo de movimiento para clasificarlo como típico, atípico o de otra categoría. Para obtener los videos necesarios, se consideró el uso de un conjunto de videos disponible públicamente. Las figuras 2.1 y 2.2 ilustran el esquema general de este proceso.

### Fase de entrenamiento

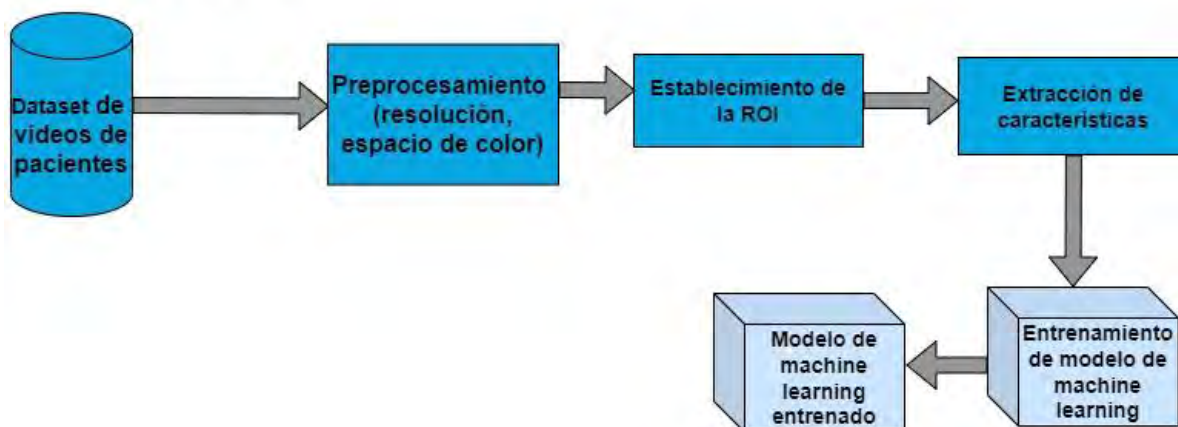


Figura 2.1 Arquitectura del sistema. Fase de entrenamiento.

Fase de clasificación

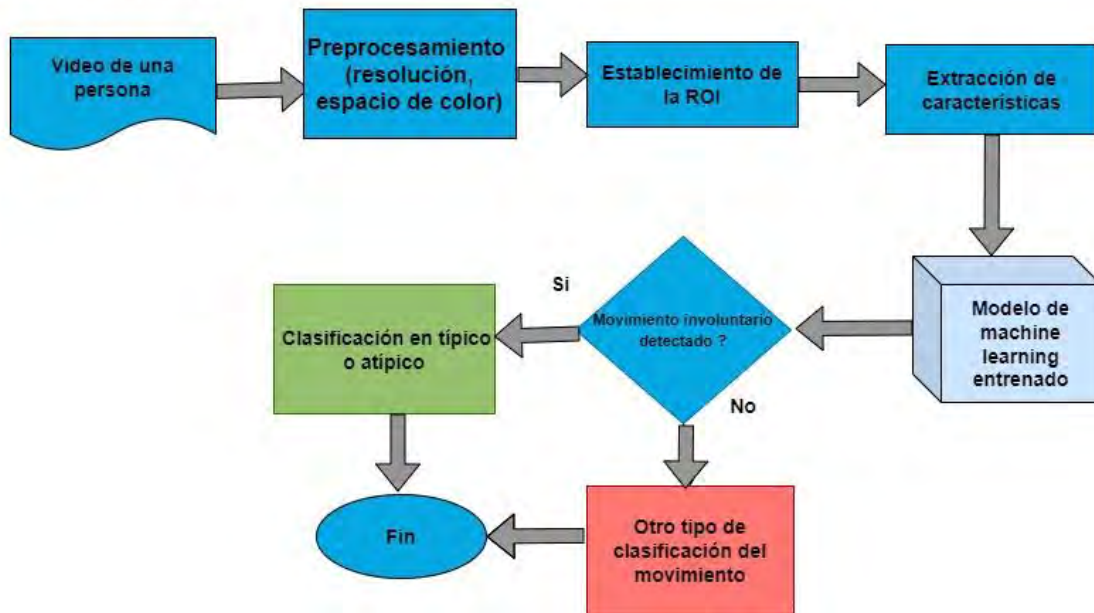


Figura 2.2 Arquitectura del sistema. Fase de clasificación.

## 3. Análisis, diseño e implementación del sistema

En este capítulo, se describe el análisis y diseño del proceso para realizar la implementación del modelo, clasificando los movimientos involuntarios para la enfermedad del Parkinson presentes en una persona. El proceso incluye las siguientes etapas: localización de la región de interés (ROI), extracción de características, preprocesamiento de datos y el entrenamiento para clasificación de movimientos en típico, atípico y sano.

### 3.1 Arquitectura del sistema

El sistema emplea una secuencia estructurada de actividades diseñadas para abordar el problema planteado y clasificar los distintos tipos de movimientos involuntarios. Estas tareas, representadas en las figuras 2.1 y 2.2, se organizan en dos fases principales: la Fase de Entrenamiento y la Fase de Clasificación.

- Fase de Entrenamiento:
  - **E1** Adquisición del Dataset de Videos de Pacientes: Se utiliza un conjunto de videos para alimentar el sistema con datos relevantes.
  - **E2** Preprocesamiento: Los videos pasan por un proceso de ajuste de resolución y espacio de color para asegurar uniformidad y calidad en el análisis.
  - **E3** Establecimiento de la Región de Interés (ROI): Se delimita el área del video que contiene información esencial para la detección de movimientos, enfocándose en la región de interés.
  - **E4** Extracción de Características: Se extraen características específicas de la región de interés para identificar patrones que ayuden en la detección de movimientos.
  - **E5** Entrenamiento del modelo de *machine learning*: Se entrenan varios modelos para una futura clasificación.
  
- Fase de Clasificación:
  - **C1** Evaluación de Video de una Persona: El sistema analiza un nuevo video para determinar el tipo de movimiento.
  - **C2** Se repiten los pasos **E2**, **E3** y **E4**.
  - **C3** Clasificación en Típico o Atípico: Con el modelo entrenado generado en el paso **E5**, el sistema decide si el movimiento detectado es típico o atípico.
  - **C4** Clasificación en Otra Categoría: Si no es involuntario, se clasifica en otra categoría de movimientos.

A continuación, se mencionan las acciones realizadas seguidas de una breve explicación.

**Dataset de videos de pacientes:** Para la adquisición de videos representativos de los movimientos de interés para la investigación, se realizaron reuniones con centros médicos como el INNN y el Centro de Investigación Transdisciplinar en Psicología buscando establecer convenios. Se llenó y envió un documento que representa el formato de investigación clínica que utilizan los doctores en el INNN; sin embargo, no se tuvo respuesta por parte de los mismos. A falta de un dataset, se procedió a buscar y seleccionar videos para la investigación en la plataforma de *YouTube*. Dicho material consiste en videos de personas con temblores en reposo y postural de las manos, así como disquinesias faciales.

**Preprocesamiento:** Las tareas que se realizaron en esta fase fueron las de escalado y conversión a espacio de colores de las imágenes recopiladas por medio de los videos.


**Establecimiento de la ROI:** Esta fase consiste en capturar las coordenadas espaciales de la región de las manos y de la boca para la detección y análisis de temblores y discinesias respectivamente, a través de la herramienta de *MediaPipe*.

**Extracción de características:** Esta fase incluye el cálculo de determinadas variables de interés para formar un vector de características y entrenar un modelo determinado de *machine learning*.

**Modelo de machine learning:** Se utiliza el vector obtenido de la fase previa, para el entrenamiento y validación de una arquitectura de aprendizaje. Se tuvo en cuenta específicamente usar algunos clasificadores clásicos (RF, KNN, SVM) y otros de aprendizaje profundo como CNN, MLP y LSTM.

### 3.1.1 Etapa de establecimiento de la ROI

Para establecer la localización de las regiones de interés (ROI) en la zona de las manos, se procedió inicialmente a la detección de puntos de referencia a través de la herramienta *Media pipe* en su versión 0.10. Esta herramienta da como resultado la detección de 21 puntos de referencia y el posterior seguimiento o tracking de dichos puntos obtenidos con el módulo *handLandmarker*. La figura 3.1 muestra las *landmarks* obtenidas con dicha herramienta con una persona sana como sujeto de prueba. De forma análoga, se escogieron los puntos de referencia de interés para la región de la boca a través del módulo *face\_landmarker\_v2\_with\_blendshape*. Las figuras 3.2 y 3.3 muestran dicha representación.



**Figura 3.1** *Detección de landmarks de la mano.*



**Figura 3.2** *Landmarks originales obtenidas con el módulo face\_landmarker\_v2\_with\_blendshape.*



**Figura 3.3** Landmarks de la zona de la boca usadas para el análisis de características.

Los videos analizados son los que presentan el temblor de manos, en la posición de reposo; así como en el llamado temblor postural en el cual el paciente estira los brazos en posición horizontal al frente de su tronco, con las palmas de las manos orientadas hacia el piso. La ROI se encerró en una caja (sólo para el caso de la zona de las manos). Teniendo en cuenta la coordenada  $x$  como el ancho y la coordenada  $y$  como la altura, se calculó el centro de estas coordenadas de los puntos de referencia, así como la mitad del ancho y la longitud para que pudieran restarse y sumarse al centro. Luego, se multiplicó por un factor de escala de 1.5. De esta manera, la ROI quedó correctamente encerrada en una caja. La Figura 3.4 muestra los resultados de este procedimiento.






Figura 3.4 Región de las manos con temblores encerradas en un cuadro.

### 3.1.2 Extracción de características

Luego de la obtención de la ROI debido a las *landmarks* se procedió a efectuar al análisis de dicha región para la extracción de características relevantes. Se calcularon usando una ventana temporal de 9 fotogramas de video, características como magnitud (distancia), ángulo, amplitud del movimiento del temblor, velocidad y aceleración. Se encontró el promedio de esta magnitud y se añadió a una lista que contenía todos los valores de magnitud. Luego, se aplicó la Transformada Discreta del Coseno para obtener las frecuencias de las magnitudes.


Se aplicó un filtro de paso de banda entre 4-7 Hz (Pasquini et al., 2018 para identificar temblores posturales y en reposo. Si el valor de la frecuencia estaba en el rango esperado, se procedió a encerrar la ROI en una caja. Esta tarea generó como resultado un vector de características como magnitud, ángulo, frecuencia, amplitud, velocidad, aceleración del temblor para ser usado en el entrenamiento de un modelo de *machine learning*.

En el procesamiento de videos de pacientes con discinesias faciales, se aplican los mismos cálculos utilizados para los videos de temblores, incorporando además nuevas características, incluido el análisis de Procrustes (Zhu et al., 2020). Esta técnica es fundamental para evaluar la simetría en puntos anatómicos clave, en este caso, en la zona de la boca, ojos, cejas y el contorno facial. El análisis de Procrustes es un método estadístico que permite comparar formas geométricas mediante transformaciones de

escala, rotación y traslación, minimizando así las diferencias entre conjuntos de puntos. En el análisis facial, se utiliza para alinear una imagen original con su versión reflejada y calcular las discrepancias en la distribución de los puntos de referencia anatómicos, proporcionando una evaluación precisa de la asimetría.

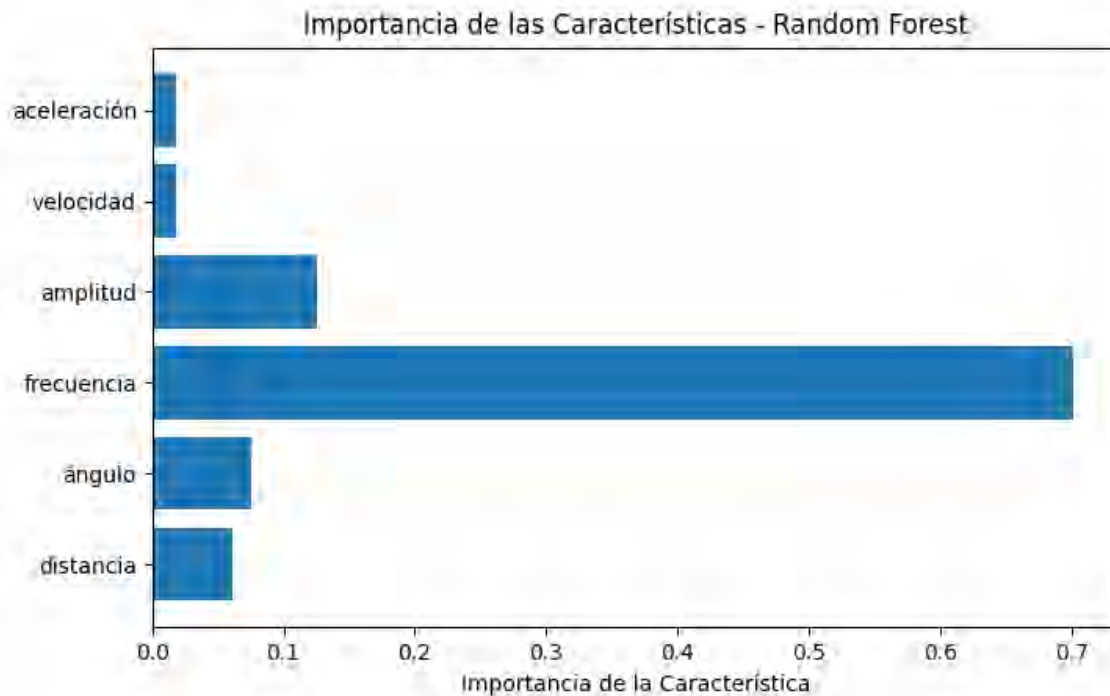
### 3.1.3 Preprocesamiento de los datos

En esta etapa se procedió, con el vector de características generado tras el procesamiento de los videos, a realizar una limpieza en los datos (eliminación de espacios). También se realizó un escalado de las características obtenidas para que el modelo no les diera mayor importancia a los valores de alguna columna determinada. Se utilizó el evaluador de importancia de las características de *Random Forest*, para determinar cuál influía más en el modelo. El resultado se muestra en la figura 3.5, la cual presenta las características y su relativa importancia asociadas a los videos de personas con discinesias.



**Figura 3.5** Resultado de la importancia de las características. Las que más aportan al modelo son la 10 (disparidad en zona de la silueta facial), seguidas de la 4 (amplitud) y la 7 (disparidad en zona de los ojos).

Para el caso de los videos analizando los temblores, la importancia de las características se refleja en la figura 3.6.



**Figura 3.6** Resultado de la importancia de las características. En el caso de temblores, la característica 3 (frecuencia) es la más importante.

## 3.2 Modelos de aprendizaje usados

En esta sección se abordan los modelos de *machine learning* estudiados que eran factibles para la solución del problema investigativo. Estos son las redes neuronales convolucionales, las redes LSTM, el perceptrón multicapa y los clasificadores clásicos.

### 3.2.1 Red CNN

Inicialmente se contempló la opción de *yolov8* (Reis et al., 2023) para el análisis de los *frames* del video, teniendo en cuenta algunas de las ventajas de la red, la cual consiste en aprender a extraer patrones complejos que son útiles para el modelo. Al no poder utilizar una herramienta de etiquetado automático, se hizo de forma manual, llegando a tener 1258 imágenes representativa de las 3 clases. Se le agregó el vector de características construido y se procedió a realizar el entrenamiento. El resultado del mismo se muestra en la figura 3.7. Al no tener los valores de métricas esperados, se descartó esa solución.

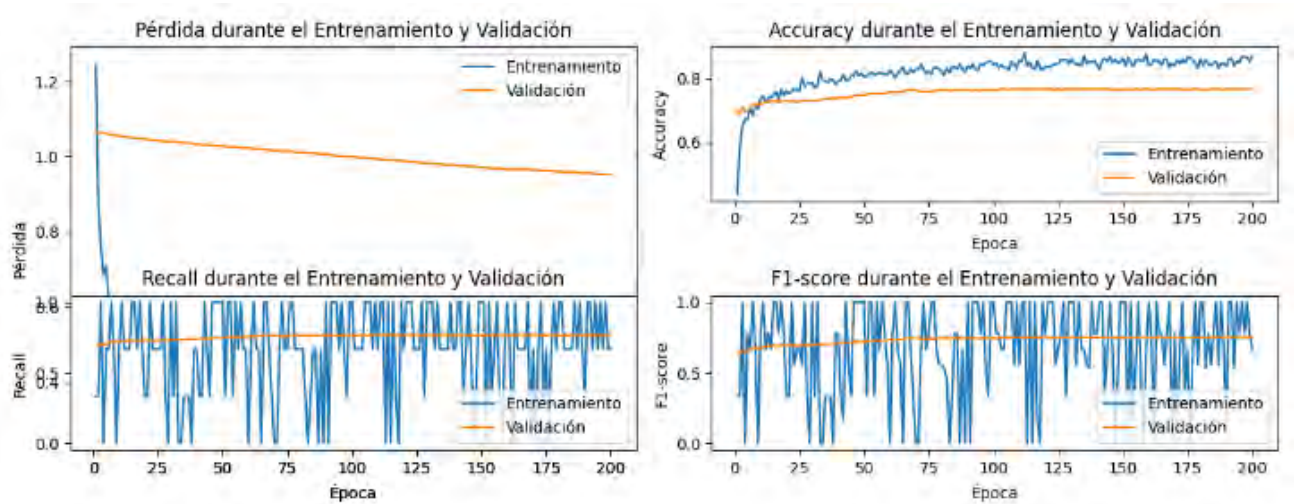


Figura 3.7 Gráficas del entrenamiento y las métricas obtenidas con yolov8.

### 3.2.2 Red LSTM

Para el entrenamiento de dicha red, se realizó una búsqueda *GridSearch* para el cálculo de los mejores parámetros, obteniéndose los siguientes valores:

**Longitud de secuencia:** 30

**Número de características:** 10

**Capas lstm:** 2 de 128 y 64 unidades respectivamente.

**Dropout:** 0.2 y 0.3

**Capa densa:** 3 neuronas con función de activación *softmax*

**Optimizador:** Adam

**Tasa de aprendizaje:** 0.001

**Número de épocas:** 100

### 3.2.3 Perceptrón multicapa

Para realizar el entrenamiento de la red, se hizo de forma análoga a la red LSTM una búsqueda de los mejores parámetros con la técnica *GridSearch* seguida de una validación cruzada con  $k=5$ . Los mejores valores obtenidos fueron los siguientes:

**Capa Densa:** 64 unidades con función de activación *relu*.

**Dropout:** 0.3

**Capa Densa:** 64 unidades con función de activación *relu*.

**Dropout:** 0.3

**Capa Densa:** 3 unidades con función de activación *softmax*.

**Optimizador:** *Adam*.

**Tasa de aprendizaje:** 0.0001

**Número de épocas:** 150

**Tamaño de lotes:** 32

Para realizar una comparación con los modelos de aprendizaje profundo (red LSTM y MLP), se ocuparon los clasificadores clásicos RF, SVC (clasificador de máquina de vectores de soporte) y KNN.

### 3.3 Interfaz del sistema

A continuación, se presenta y describe brevemente la interfaz del sistema.

Módulo de detección de manos: Se marca el *radiobutton* para realizar la detección de temblores postural y reposo en la zona de las manos.

Módulo de detección de zona de boca: Se marca el *radiobutton* para realizar la detección de discinesia facial en la zona de boca, ceja, ojos y la silueta del rostro.

Cargar video: Le da la opción al cliente de proporcionar la ruta de un video en específico para su análisis.

Usar Webcam: Realiza la captura de video en tiempo real para su análisis.

Clasificar con MLP: Se realiza la clasificación del video antes capturado en una de las 3 clases posibles (temblor, discinesia y sano) usando el perceptrón multicapa.

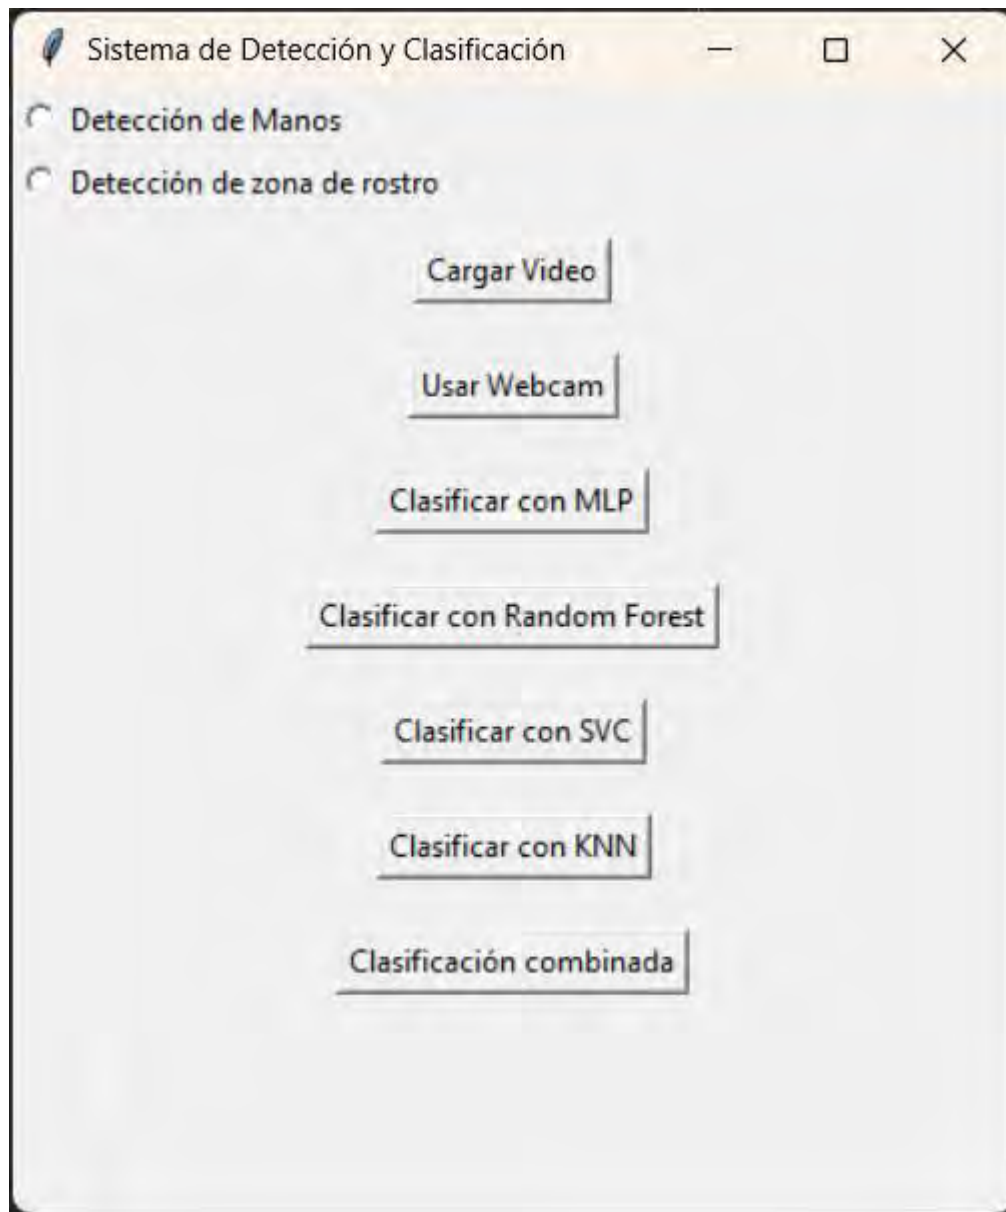
Clasificar con *Random Forest*: Se realiza la clasificación del video antes capturado en una de las 3 clases posibles (temblor, discinesia y sano) usando el clasificador de *random forest*.

Clasificar con SVC: De forma análoga a las anteriores, se analiza el video capturado usando el clasificador de las máquinas de vectores de soporte.

Clasificar con KNN: Se realiza la clasificación del video en cuestión a través del algoritmo de vecinos más cercanos.

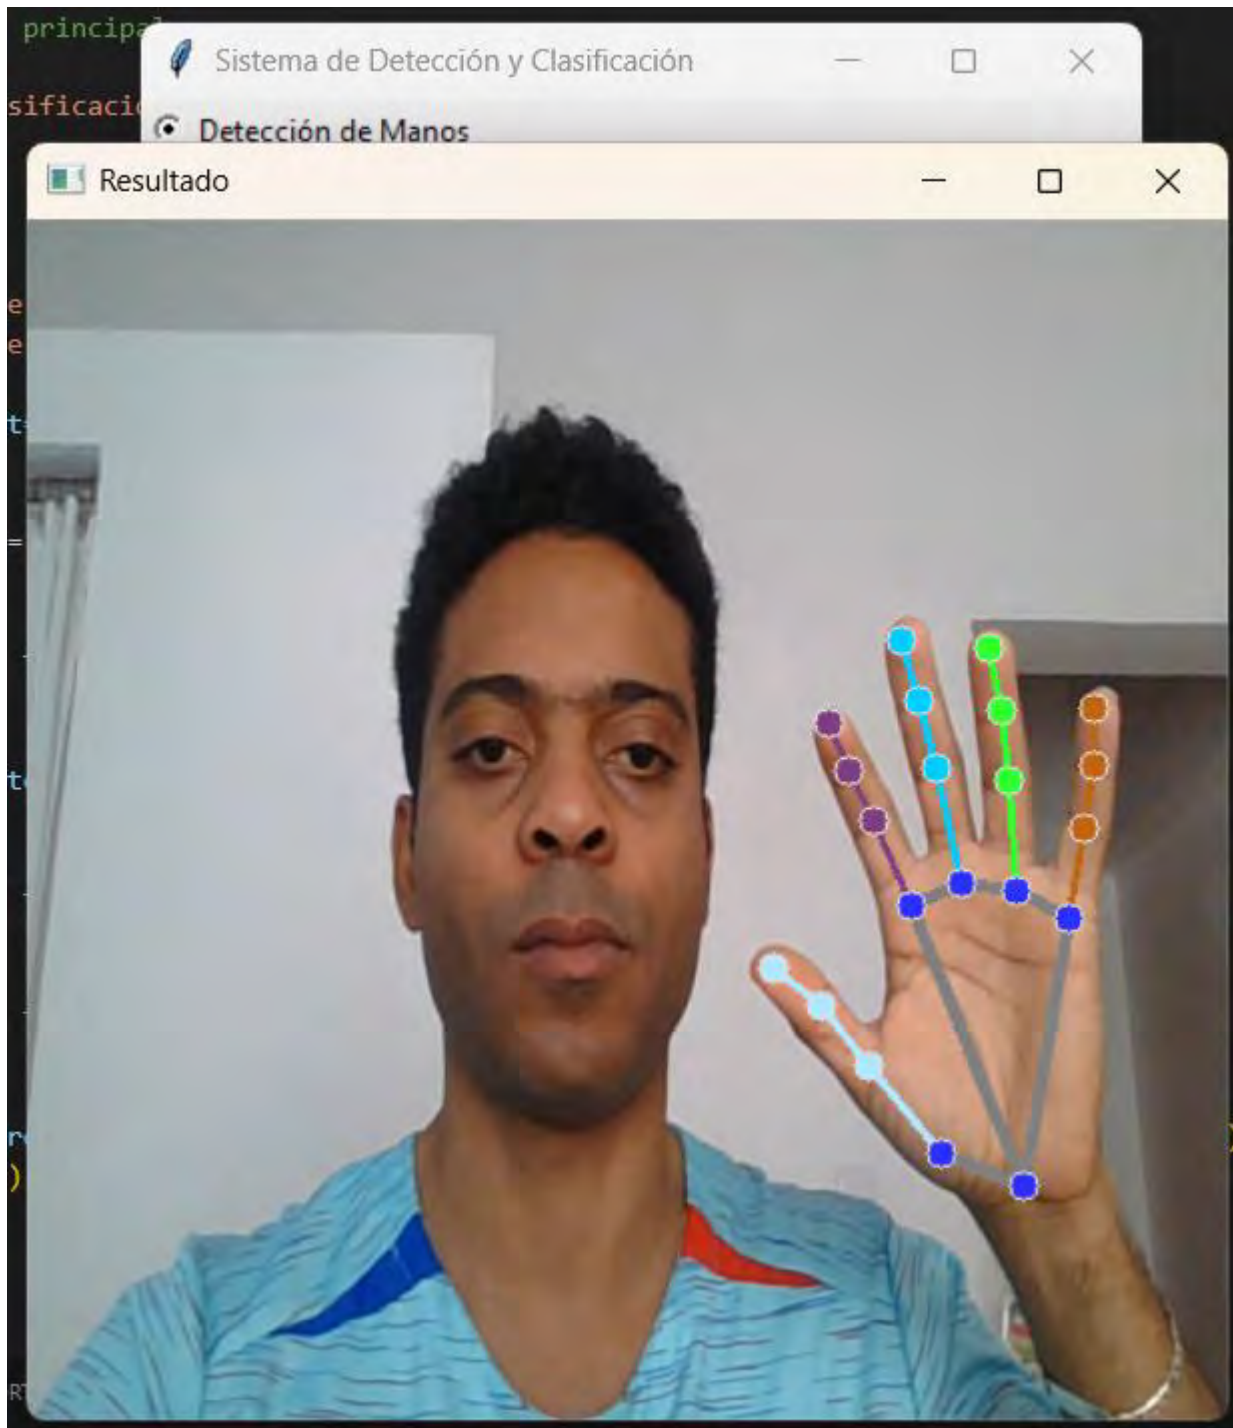
Clasificación combinada: A través de este botón se realiza la clasificación del video capturado, empleando un meta clasificador. Este posee como estimadores a los modelos de *Random Forest*, SVC, MLP y KNN. Como estimador final se utiliza a *Logistic Regression*.

Las funcionalidades descritas, se muestran en la figura 3.8.



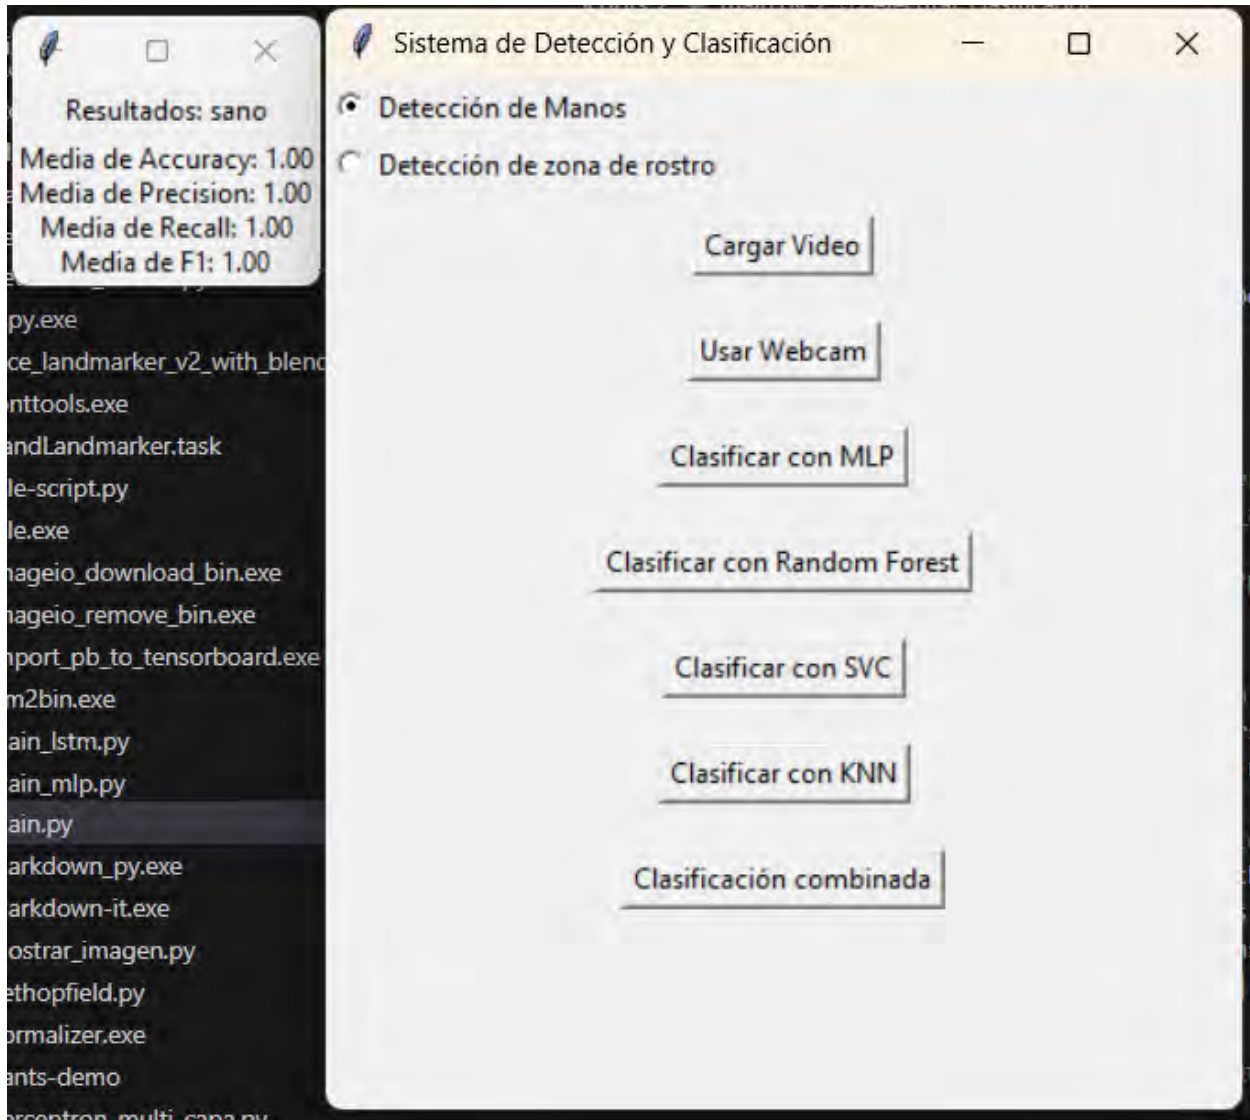
**Figura 3.8** *Interfaz principal del sistema*

A continuación, la figura 3.9 muestra el uso de la webcam para realizar la detección y clasificación del movimiento en la zona de las manos.



**Figura 3.9** Detección de manos con la webcam. Sujeto sano.

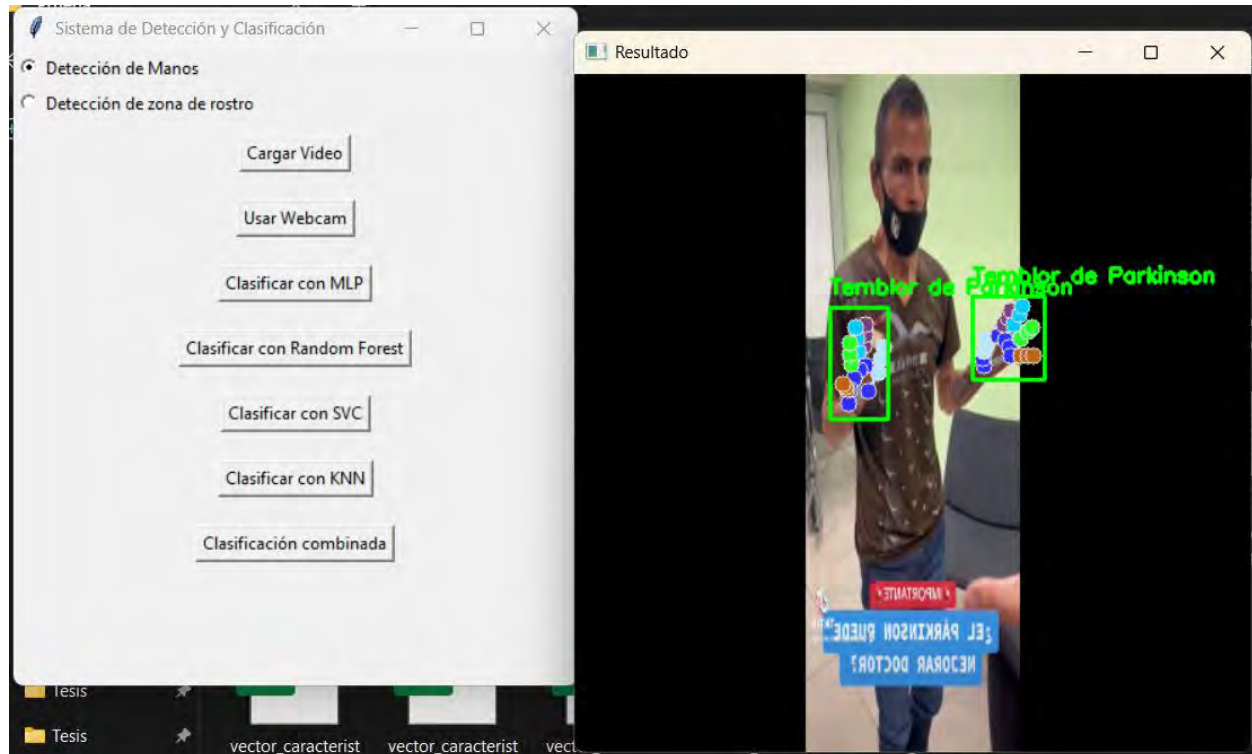
La salida, para el ejemplo ilustrado en este documento, con el uso del MLP se muestra en la figura 3.10.



**Figura 3.10** Resultado de aplicar MLP al video.

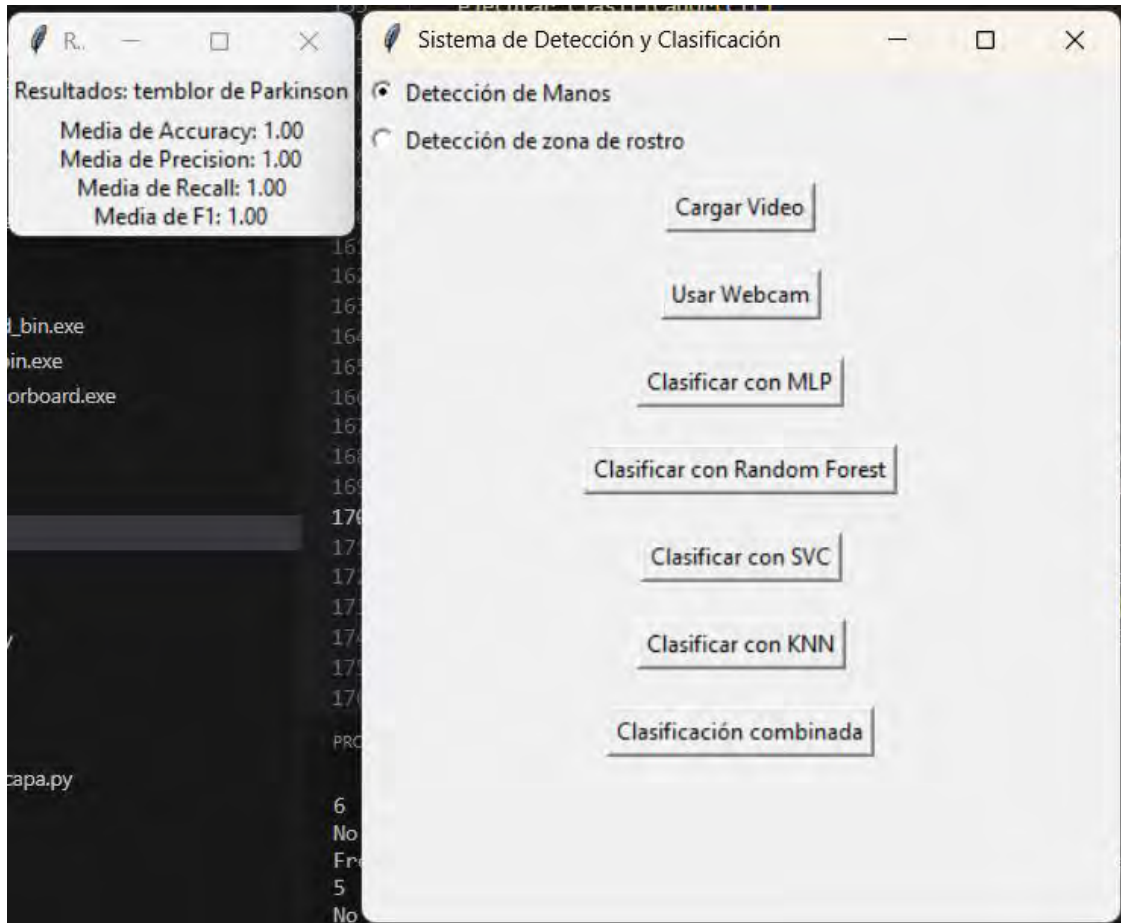
A continuación, se muestra en la figura 3.11 una persona con temblor parkinsoniano.





**Figura 3.11** Persona con temblor del Parkinson.

La salida del análisis del movimiento mediante el algoritmo de *Random Forest*, de la persona de la Figura 3.11, se muestra en la Figura 3.12.



**Figura 3.12** Resultado de aplicar Random Forest a un video nuevo. Paciente con temblores de Parkinson.

De forma análoga, se realizó el análisis de la zona del rostro. A continuación, en las figuras 3.13 y 3.14 se ilustra la carga del video de un paciente con discinesia facial y el resultado de clasificación.




Figura 3.13 Paciente con discinesia facial.

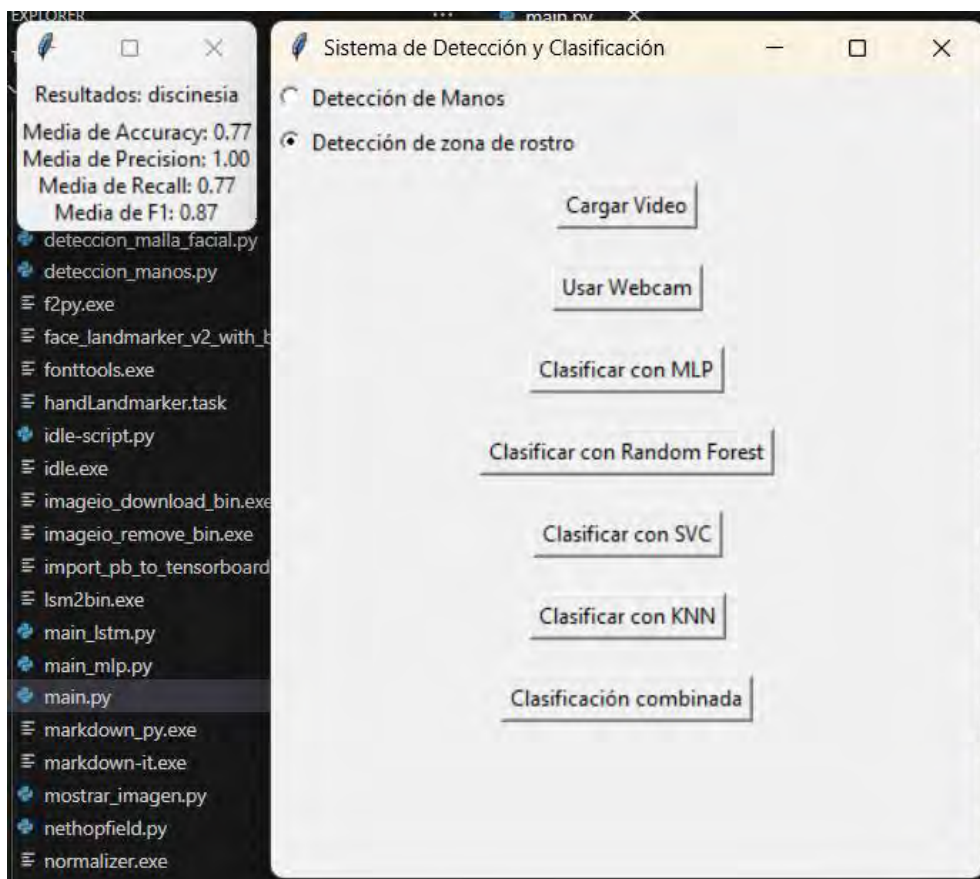


Figura 3.14 Resultado obtenido después de aplicar KNN.

## 4. Experimentación y análisis de resultados

En este capítulo, se esbozan los experimentos realizados, así como un análisis de los resultados de dicha experimentación. Se verifica si los resultados dan cumplimiento a los objetivos y alcances propuestos. Por último, se especifica el aporte de la investigación llevada a cabo desde el punto de vista computacional.

### 4.1 Objetivos y alcances

Para la experimentación y posterior análisis de los resultados obtenidos, se consideraron los siguientes objetivos y alcances:

#### Desglose de objetivos:

- O1.** Modelar patrones típicos de movimientos involuntarios.
- O2.** Detectar movimientos atípicos.
- O3.** Adquirir datos visuales de movimientos en personas.
- O4.** Utilizar técnicas de IA para analizar patrones de movimientos.

#### Desglose de alcances:

- A1.** Identificar patrones analizando imágenes de una persona a la vez.
- A2.** Detectar patrones de movimientos involuntarios en cualquier persona.
- A3.** Modelar algoritmos que realicen localización de personas en un ambiente controlado.
- A4.** Seleccionar un modelo de machine learning para aprender al menos un patrón típico en los TDM.
- A5.** Reconocer al menos un movimiento anormal dentro de los TDM.
- A6.** Entrenar y probar con datos adquiridos mediante visión por computador o cámaras RGB con profundidad.

### 4.2 Experimentación

Para la experimentación, se utilizó como hardware el siguiente:

- Laptop MSI GF63 con procesador Core i5-11400H, con 32 GB de RAM y una tarjeta gráfica NVIDIA GeForce RTX 3050 de 4 GB.
- Cámara convencional de un smartphone Xiaomi 11T pro con 108 mp.

El lenguaje de programación se utilizó *Python* en su versión 3.10.13. Como herramienta de detección y seguimiento de las *landmarks* se ocupó *MediaPipe* en su versión 0.10.8. Como dataset, se utilizó un *corpus* formado por los videos recopilados de *YouTube*, consistentes en 26 videos de temblores de 9 pacientes, 30 videos de 11

pacientes con discinesias y 24 videos de 8 personas sanas. La distribución de los mismos para los conjuntos de entrenamiento, validación, prueba y datos a clasificar fue la siguiente:

- 16 videos de pacientes de Parkinson, 15 de personas con discinesias y 17 de personas sanas para entrenamiento, total de 48 videos.
- 3 videos de pacientes de Parkinson, 5 de personas con discinesias y 3 de personas sanas para validación, total de 11 videos.
- 3 videos de pacientes de Parkinson, 3 de personas con discinesias y 4 de personas sanas para prueba, total de 10 videos.
- 4 videos de pacientes de Parkinson, 7 de personas con discinesias y 3 de personas sanas como datos a clasificar, total de 11 videos y 3 archivos.

De forma resumida, se muestra dicha información en la tabla 4.1

**Tabla 4.1** Cantidad de videos usados para conformar los vectores de características, separados por clases.

Archivo de datos	Sujeto con Parkinson	Sujeto con discinesia	Sujeto sano
Entrenamiento	16	15	17
Validación	3	5	3
Prueba	3	3	4
Datos nuevos	4	7	3

Los experimentos realizados se enuncian a continuación:

- Video de zona de manos de persona con temblor de Parkinson.
- Video de zona de manos de persona sin temblor de Parkinson.
- Video de zona de rostro de persona con discinesia.
- Video de zona de rostro de persona sin discinesia.

Se llevaron a cabo dichos casos de experimentación con el propósito de verificar el cumplimiento de los objetivos y alcances establecidos en la sección 4.1. En particular, los dos primeros experimentos se realizaron para confirmar el cumplimiento de todos los objetivos y alcances, exceptuando el **O2** y el **A5**. Por su parte, los últimos experimentos, centrados en la zona del rostro, se enfocaron en garantizar el cumplimiento de todos los objetivos y alcances, excepto el **O1** y el **A4**.

El objetivo de la experimentación es identificar el modelo de *machine learning* que clasifica con mayor precisión los datos nuevos. La evaluación se llevó a cabo utilizando métricas clásicas: exactitud (*accuracy*), precisión (*precision*), sensibilidad (*recall*) y puntaje F1 (*f1\_score*). Se considera que la experimentación es satisfactoria si se alcanza una exactitud del 95 % en la clasificación del temblor de Parkinson, tal como lo reporta el estado del arte, y del 90 % en la detección de movimientos discinéticos faciales. Es importante destacar que este tipo de discinesia no ha sido previamente evaluado en los

artículos revisados del estado del arte.

Para los experimentos, se analizó un total de 14 videos: 4 correspondientes a temblores de manos, 7 de discinesias faciales y 3 de personas sanas. Además, se generaron 3 archivos adicionales con datos de la zona del rostro de personas sanas para su clasificación. Primeramente, se procedió a la tarea de ver la cantidad de videos etiquetados correctamente, independientemente de la métrica obtenida. A continuación, se ilustran en la tabla 4.2, los resultados de la aplicación de los algoritmos a los datos a clasificar respecto a la cantidad de datos etiquetados.

**Tabla 4.2** Experimento 1. Comparación de resultados con clasificadores clásicos y red LSTM.

Algoritmo	Clasificación correcta	Clasificación incorrecta
RF	6	2
KNN	6	2
SVC	6	2
LSTM	6	2

En algunos casos en que la red LSTM clasificaba correctamente los datos, las métricas obtenidas fueron muy bajas respecto a la meta a alcanzar (95% de *accuracy* para temblores y 90% para discinesias). Esto se puede ver en la tabla 4.3, específicamente en el caso de temblor de manos. Cabe destacar que sí hubo otros donde clasificó correctamente y se alcanzaron las métricas esperadas, como se puede apreciar en los otros casos de estudio de la misma tabla.

**Tabla 4.3** Métricas obtenidas con red LSTM y los 3 casos de estudio.

Caso de estudio	Exactitud	Precisión	Recall	F1-score
Temblor de manos	0.57	1.00	0.57	0.58
Sujeto sin discinesia	0.92	0.93	0.92	0.88
Sujeto con discinesia	0.93	0.91	0.93	0.89

La implementación de la red LSTM no produjo los resultados esperados, principalmente debido a la limitada disponibilidad de datos y a que este tipo de red, al requerir una gran cantidad de datos para aprender patrones temporales de manera efectiva, no pudo optimizarse adecuadamente. Por esta razón, se optó por implementar un perceptrón multicapa para realizar experimentos adicionales y tratar de alcanzar las métricas deseadas. En la tabla 4.4 se visualiza una muestra de la cantidad de videos clasificados con dicho algoritmo, comparándose además con los clasificadores clásicos.

**Tabla 4.4 Experimento 2. Comparación de resultados con clasificadores clásicos y MLP.**

Algoritmo	Clasificación correcta	Clasificación incorrecta
RF	6	2
KNN	5	3
SVC	5	3
MLP	5	3

Las tablas mostradas en las 3 secciones siguientes presentan los resultados de la clasificación y las métricas obtenidas para cada uno de los modelos utilizados. Se emplearon cuatro videos en dicha tarea: dos para el análisis de temblor, con su correspondiente etiquetado como temblor (clase 0) o sano (clase 1), y dos para el análisis de discinesias, etiquetándolos de igual forma como discinesia (clase 2) o sano (clase 1).

#### 4.2.1 Clasificación para la clase temblor

Para la clase de temblor de manos, los resultados obtenidos con los 4 algoritmos fueron satisfactorios. Prueba de ello constituye la tabla 4.5 mostrada a continuación.

**Tabla 4.5 Métricas obtenidas con los 4 algoritmos en un video con temblor de manos.**

Algoritmo	Exactitud	Precisión	Recall	F1-score
MLP	1.0	1.0	1.0	1.0
RF	1.0	1.0	1.0	1.0
SVC	1.0	1.0	1.0	1.0
KNN	1.0	1.0	1.0	1.0

#### 4.2.2 Clasificación para la clase discinesia

En la tabla 4.6 se ilustran los resultados obtenidos con un video de una persona con discinesia facial. En ella se puede apreciar como el algoritmo de RF falla al clasificar.

**Tabla 4.6 Métricas obtenidas con los 4 algoritmos en un video de persona con discinesia.**

Algoritmo	Exactitud	Precisión	Recall	F1-score
MLP	0.97	0.97	0.97	0.95
RF	0.09	0.94	0.09	0.13
SVC	0.97	0.97	0.97	0.95
KNN	0.67	0.94	0.67	0.78

### 4.2.3 Clasificación para la clase sano

En la tabla 4.7 se ilustran los resultados obtenidos al analizar un video de una persona sin discinesia facial. El algoritmo RF es el único que presentó resultados satisfactorios.

**Tabla 4.7 Métricas obtenidas con los 4 algoritmos en un video de persona sin discinesia.**

Algoritmo	Exactitud	Precisión	Recall	F1-score
MLP (manos)	0.66	0.83	0.66	0.62
MLP (rostro)	0.20	0.83	0.20	0.07
RF (manos)	1.00	1.00	1.00	1.00
RF (rostro)	1.00	1.00	1.00	1.00
SVC (manos)	0.34	0.40	0.34	0.36
SVC (rostro)	0.20	0.83	0.20	0.07
KNN (manos)	0.78	0.82	0.78	0.78
KNN (rostro)	0.20	0.83	0.20	0.07

A continuación, se presentan en las tablas de la 4.9 a la 4.11, los porcentajes de clasificación obtenidos para las clases temblor, discinesia y sano, según las métricas evaluadas.

**Tabla 4.8 Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica accuracy.**

Algoritmo	Acc. temblor	Acc. discinesia	Acc. sano
MLP	0.95	0.96	0.31
<b>RF</b>	<b>1.00</b>	<b>0.96</b>	<b>0.96</b>
SVC	0.45	0.99	0.40
kNN	0.66	0.82	0.31

**Tabla 4.9 Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica precision.**

Algoritmo	Prec. temblor	Prec. discinesia	Prec. sano
MLP	0.97	0.98	0.66
<b>RF</b>	<b>1.00</b>	<b>0.99</b>	<b>0.96</b>
SVC	0.88	0.98	0.88
kNN	0.92	0.98	0.72



**Tabla 4.10** Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica recall.

Algoritmo	Rec. temblor	Rec. discinesia	Rec. sano
MLP	0.95	0.97	0.31
<b>RF</b>	<b>1.00</b>	<b>0.96</b>	<b>0.96</b>
SVC	0.45	0.99	0.30
kNN	0.66	0.82	0.40

**Tabla 4.11** Porcentajes de clasificación en 14 videos y los 3 archivos por clases. Métrica f1-score.

Algoritmo	F1. temblor	F1. discinesia	F1. sano
MLP	0.96	0.98	0.30
<b>RF</b>	<b>1.00</b>	<b>0.96</b>	<b>0.95</b>
SVC	0.55	0.98	0.24
kNN	0.71	0.90	0.41

A continuación, se muestran los resultados obtenidos en todos los algoritmos para las etiquetas en cuestión. Se especifican las métricas resultantes de las experimentaciones finales que abarca el MLP y clasificadores clásicos con 3 clases.

**Tabla 4.12** Promedio de las métricas accuracy, precision, recall y f1\_score para los algoritmos en todas las clases. Experimentación con 3 clases.

Algoritmo	Media Acc.	Media Prec.	Media Rec.	Media f1_score
MLP	0.74	0.87	0.74	0.74
<b>RF</b>	<b>0.97</b>	<b>0.98</b>	<b>0.97</b>	<b>0.97</b>
SVC	0.61	0.91	0.58	0.59
KNN	0.59	0.87	0.62	0.67

Se realizaron otros experimentos comenzando con la región de las manos, utilizando las etiquetas **temblor** y **no temblor**. Posteriormente, se llevó a cabo un experimento similar con la región del rostro, generando las etiquetas **discinesia** y **no discinesia**. A continuación, se combinaron los conjuntos de entrenamiento de ambas regiones de interés para evaluar el rendimiento del algoritmo de clasificación al etiquetar un nuevo video en una de las cuatro clases posibles: **temblor**, **no temblor**, **discinesia** y **no discinesia**. El objetivo de estas experimentaciones adicionales fue determinar si los resultados eran comparables a los obtenidos con el entrenamiento inicial de las tres clases juntas. Los resultados de los restantes experimentos se muestran a continuación.

#### 4.2.4 Experimentación en zona de manos

En la segunda experimentación, se separaron las etiquetas en la forma temblor y no temblor. Se evaluaron con los mismos algoritmos y videos que en el experimento 1. A

continuación se presentan los resultados obtenidos para las métricas *accuracy*, *precision*, *recall* y *f1\_score* en las tablas de la 4.13 a la 4.16.

**Tabla 4.13** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica accuracy.*

Algoritmo	Acc. temblor	Acc. No temblor
MLP	0.50	1.00
<b>RF</b>	<b>0.90</b>	<b>1.00</b>
SVC	0.24	0.90
KNN	0.59	0.87

**Tabla 4.14** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica precision.*

Algoritmo	Prec. temblor	Prec. No temblor
MLP	0.70	1.00
<b>RF</b>	<b>1.00</b>	<b>1.00</b>
SVC	0.45	1.00
KNN	0.70	1.00

**Tabla 4.15** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica recall.*

Algoritmo	Rec. temblor	Rec. No temblor
MLP	0.50	1.00
<b>RF</b>	<b>0.90</b>	<b>1.00</b>
SVC	0.24	0.95
KNN	0.59	0.87

**Tabla 4.16** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica f1\_score.*

Algoritmo	F1. temblor	F1. No temblor
MLP	0.52	1.00
<b>RF</b>	<b>0.93</b>	<b>1.00</b>
SVC	0.29	0.93
KNN	0.62	0.93

#### 4.2.5 Experimentación en zona de rostro

En la tercera experimentación se procedió a realizar la clasificación usando las etiquetas discinesia y no discinesia. De forma análoga a los experimentos anteriores se emplearon

los mismos algoritmos y videos correspondientes a la región de análisis. A continuación, se presentan los resultados obtenidos en las tablas de la 4.17 a la 4.20.

**Tabla 4.17** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica accuracy.*

Algoritmo	Acc. discinesia	Acc. No discinesia
<b>MLP</b>	<b>0.92</b>	<b>0.15</b>
RF	0.08	0.74
SVC	0.03	0.86
KNN	0.03	0.80

**Tabla 4.18** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica precision.*

Algoritmo	Prec. discinesia	Prec. No discinesia
MLP	0.95	0.88
<b>RF</b>	<b>0.95</b>	<b>0.91</b>
SVC	0.95	0.87
KNN	0.97	0.86

**Tabla 4.19** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica recall.*

Algoritmo	Rec. discinesia	Rec. No discinesia
<b>MLP</b>	<b>0.92</b>	<b>0.15</b>
RF	0.08	0.74
SVC	0.03	0.86
KNN	0.03	0.80

**Tabla 4.20** *Porcentajes de clasificación en 14 videos y los 3 archivos separados en 2 clases. Métrica f1\_score.*

Algoritmo	F1. discinesia	F1. No discinesia
<b>MLP</b>	<b>0.93</b>	<b>0.05</b>
RF	0.13	0.77
SVC	0.01	0.84
KNN	0.01	0.76

A continuación, se muestran los resultados obtenidos en todos los algoritmos para las etiquetas en cuestión. Se especifican las métricas resultantes de las experimentaciones finales que abarca el MLP y clasificadores clásicos con 4 clases.

**Tabla 4.21** Promedio de las métricas accuracy, precision, recall y f1\_score para los algoritmos en todas las clases. Experimentación con 4 clases.

Algoritmo	Media Acc.	Media Prec.	Media Rec.	Media f1_score
MLP	0.64	0.88	0.64	0.63
RF	0.68	0.97	0.68	0.71
SVC	0.51	0.82	0.51	0.52
KNN	0.57	0.88	0.57	0.58

### 4.3 Análisis de resultados

Posteriormente se procedió a verificar si todos los algoritmos implementados cumplieron con los objetivos y alcances trazados. Los principales alcances definidos son identificar un patrón típico dentro de los TDM, así como reconocer al menos un movimiento anormal dentro de los trastornos con respecto al comportamiento de los movimientos aprendidos. En la tabla 4.22 se especifican los resultados obtenidos.

**Tabla 4.22** Matriz de resultados de los experimentos vs objetivos.

Algoritmo + Condición	O1: Modelar patrones típicos	O2: Detectar movimientos atípicos	O3: Adquirir datos visuales	O4: Utilizar técnicas de IA
MLP + Persona con temblor	Si	No aplica	Si	Si
RF + Persona con temblor	Si	No aplica	Si	Si
SVC + Persona con temblor	Si	No aplica	Si	Si
KNN + Persona con temblor	Si	No aplica	Si	Si
MLP + Persona sin temblor	Si	No aplica	Si	Si
RF + Persona sin temblor	Si	No aplica	Si	Si
SVC + Persona sin temblor	Si	No aplica	Si	Si
KNN + Persona sin temblor	Si	No aplica	Si	Si

**Tabla 4.22** Matriz de resultados de los experimentos vs objetivos (continuación).

<b>Algoritmo + Condición</b>	<b>O1: Modelar patrones típicos</b>	<b>O2: Detectar movimientos atípicos</b>	<b>O3: Adquirir datos visuales</b>	<b>O4: Utilizar técnicas de IA</b>
MLP + Rostro con discinesia	No aplica	Si	Si	Si
RF + Rostro con discinesia	No aplica	Si	Si	Si
SVC + Rostro con discinesia	No aplica	Si	Si	Si
KNN + Rostro con discinesia	No aplica	Si	Si	Si
MLP + Rostro sin discinesia	No aplica	Si	Si	Si
RF + Rostro sin discinesia	No aplica	Si	Si	Si
SVC + Rostro sin discinesia	No aplica	Si	Si	Si
KNN + Rostro sin discinesia	No aplica	Si	Si	Si

De forma análoga, se presenta la tabla de los experimentos realizados, teniendo en cuenta los alcances establecidos previamente. Por motivos de espacio se representan las palabras discinesias y temblor con las abreviaturas DC y TB respectivamente.

**Tabla 4.23** Matriz de resultados de los experimentos vs alcances.

<b>Algoritmo + Condición</b>	<b>A1: Analizar una persona a la vez</b>	<b>A2: Detectar en cualquier persona</b>	<b>A3: Localizar personas en ambiente controlado</b>	<b>A4: Aprender un patrón típico</b>	<b>A5: Reconocer un movimiento anormal</b>	<b>A6: Usar datos RGB o de profundidad</b>
MLP + Persona con TB	Si	Si	Si	Si	No aplica	Si
RF + Persona con TB	Si	Si	Si	Si	No aplica	Si
SVC + Persona con TB	Si	Si	Si	Si	No aplica	Si
KNN + Persona con TB	Si	Si	Si	Si	No aplica	Si

**Tabla 4.23** Matriz de resultados de los experimentos vs alcances (continuación).

<b>Algoritmo + Condición</b>	<b>A1: Analizar una persona a la vez</b>	<b>A2: Detectar en cualquier persona</b>	<b>A3: Localizar personas en ambiente controlado</b>	<b>A4: Aprender un patrón típico</b>	<b>A5: Reconocer un movimiento anormal</b>	<b>A6: Usar datos RGB o de profundidad</b>
MLP + Persona sin TB	Si	Si	Si	Si	No aplica	Si
RF + Persona sin TB	Si	Si	Si	Si	No aplica	Si
SVC + Persona sin TB	Si	Si	Si	Si	No aplica	Si
KNN + Persona sin TB	Si	Si	Si	Si	No aplica	Si
MLP + Rostro con DC	Si	Si	Si	No aplica	Si	Si
RF + Rostro con DC	Si	Si	Si	No aplica	Si	Si
SVC + Rostro con DC	Si	Si	Si	No aplica	Si	Si
KNN + Rostro con DC	Si	Si	Si	No aplica	Si	Si
MLP + Rostro sin DC	Si	Si	Si	No aplica	No	No
RF + Rostro sin DC	Si	Si	Si	No aplica	Si	No
SVC + Rostro sin DC	Si	Si	Si	No aplica	Si	No
KNN + Rostro sin DC	Si	Si	Si	No aplica	No	No

## 5. Conclusiones

Luego del análisis de los resultados de la experimentación, se ha llegado a las siguientes conclusiones:

- Se procesó un conjunto de videos y se hizo la extracción de características claves para su etiquetado.
- Se entrenaron varios modelos de *machine learning* con el vector formado con las características extraídas.
- Se etiquetaron los videos a analizar, se evaluaron los resultados con las métricas tradicionales de *machine learning*.
- Se logró reconocer un patrón típico para el trastorno del movimiento en cuestión, así como uno atípico para dicha enfermedad.
- Se obtuvo el resultado mínimo esperado para la clasificación del temblor de Parkinson, así como para la clase discinesia.

Cabe destacar que, en la experimentación con las 2 regiones por separado, los modelos tuvieron un rendimiento bajo para la clase temblor (excepto *Random Forest*) según lo reportado en el estado del arte, pero si obtuvo el rendimiento esperado para la clase discinesia. En la experimentación con 3 clases y ambas regiones, si se alcanzaron y superaron los resultados esperados para la investigación. Por último, durante la experimentación con las 4 clases y las 2 regiones simultáneamente, se observó una disminución en el rendimiento de los modelos en las métricas asociadas a la clase temblor, además de un desempeño notablemente bajo al identificar la clase no discinesia.

### 5.1 Aportes

El desarrollo de la investigación contribuye de manera significativa en varios ámbitos:

1. Innovación en el diagnóstico de movimientos involuntarios:

Se desarrolló un modelo basado en inteligencia artificial que identifica con precisión tanto patrones típicos como atípicos asociados a movimientos involuntarios, lo cual representa un avance respecto a estudios previos que se centran exclusivamente en patrones comunes.

2. Aplicación clínica y monitoreo de enfermedades neurológicas:

El modelo propuesto facilita la detección y el seguimiento de síntomas atípicos en pacientes con trastornos del movimiento, como el Parkinson. Esto puede mejorar la calidad de vida de los pacientes y optimizar la toma de decisiones clínicas al personal médico.

### 3. Novedad en la identificación de discinesias faciales:

Por primera vez, se establecieron métricas cuantificables para la detección de discinesias faciales, lo que amplía el conocimiento en el estado del arte y abre nuevas líneas de investigación en el análisis de movimientos involuntarios.

### 4. Versatilidad y adaptabilidad del enfoque:

La metodología empleada puede extenderse a otras condiciones médicas y a distintas aplicaciones más allá del campo clínico, como el análisis de movimientos en deportes o la rehabilitación física.

### 5. Contribución tecnológica:

El uso de herramientas como MediaPipe y algoritmos de aprendizaje automático muestran la efectividad de estas tecnologías en la resolución de problemas complejos, proporcionando una guía para futuras investigaciones en inteligencia artificial aplicada.

## 5.2 Trabajo futuro

Se recomienda realizar una recopilación de más material para el entrenamiento y experimentación. De esa manera se contribuirá a la obtención de un modelo más robusto. De forma análoga, se pueden recopilar videos de otras zonas del cuerpo, para la modelación de otros movimientos involuntarios asociados a otras enfermedades neurológicas.

Como parte de la investigación, se presentó el trabajo en formato de póster durante el Evento de Inteligencia Computacional y Robótica (sección Morelos), celebrado en la Universidad Tecnológica Emiliano Zapata (UTEZ) en octubre de 2023. Asimismo, se participó con una ponencia en el Coloquio de Inteligencia Artificial, llevado a cabo en abril de 2024 en el Tecnológico de Chilpancingo. Además, se presentó un artículo en el Congreso Internacional de Tecnología y Ciencias Aplicadas (CITCA), realizado en el CENIDET en noviembre de 2024. Las constancias de participación en dichos eventos se presentan en los anexos.



# Referencias

- Ahlich, C., & Lawo, M. (2013). Parkinson's Disease Motor Symptoms in Machine Learning: A Review. *Health Informatics - An International Journal*, 2(4), 1–18. <https://doi.org/10.5121/hij.2013.2401>
- Belić, M., Bobić, V., Badža, M., Šolaja, N., Đurić-Jovičić, M., & Kostić, V. S. (2019a). Artificial intelligence for assisting diagnostics and assessment of Parkinson's disease—A review. In *Clinical Neurology and Neurosurgery* (Vol. 184). Elsevier B.V. <https://doi.org/10.1016/j.clineuro.2019.105442>
- Borzì, L., Sigcha, L., Rodríguez-Martín, D., & Olmo, G. (2023). Real-time detection of freezing of gait in Parkinson's disease using multi-head convolutional neural networks and a single inertial sensor. *Artificial Intelligence in Medicine*, 135, 102459. <https://doi.org/https://doi.org/10.1016/j.artmed.2022.102459>
- Carissimo, C., Cerro, G., Ferrigno, L., Golluccio, G., & Marino, A. (2022). Development and Assessment of a Movement Disorder Simulator Based on Inertial Data. *Sensors*, 22(17). <https://doi.org/10.3390/s22176341>
- Carrera-González, A., Llamas-Paneque, A., Montúfar-Armendáriz, S., Recalde, M., Garzón, M., Tambaco, N., & Paredes, R. (2017). *Ataxia espinocerebelosa tipo 2: diagnóstico clínico y molecular de dos casos atendidos en el Hospital de Especialidades de las Fuerzas Armadas N°1*.
- Chang, Z., Chen, Z., Stephen, C. D., Schmahmann, J. D., Wu, H.-T., Sapiro, G., & Gupta, A. S. (2020). Accurate detection of cerebellar smooth pursuit eye movement abnormalities via mobile phone video and machine learning. *Scientific Reports*, 10(1), 18641. <https://doi.org/10.1038/s41598-020-75661-x>
- Dai, H., Zhang, P., & Lueth, T. (2015). Quantitative Assessment of Parkinsonian Tremor Based on an Inertial Measurement Unit. *Sensors*, 15(10), 25055–25071. <https://doi.org/10.3390/s151025055>
- Das, S., Tariq, A., Santos, T., Kantareddy, S. S., & Banerjee, I. (2023). Recurrent Neural Networks (RNNs): Architectures, Training Tricks, and Introduction to Influential Research. In *Neuromethods* (Vol. 197, pp. 117–138). Humana Press Inc. [https://doi.org/10.1007/978-1-0716-3195-9\\_4](https://doi.org/10.1007/978-1-0716-3195-9_4)
- Discinesias*. (2023). María Del Mar Escandell. <https://www.fisioterapia-online.com/glosario/discinesias>
- Dostál, O., Procházka, A., Vyšata, O., Ťupa, O., Cejnar, P., & Vališ, M. (2021). Recognition of motion patterns using accelerometers for ataxic gait assessment. *Neural Computing and Applications*, 33(7), 2207–2215. <https://doi.org/10.1007/s00521-020-05103-2>
- Giovanni D'Addio, Carlo Ricciardi, Giovanni Improta, Paolo Bifulco, & Mario Cesarelli. (2019). Feasibility of Machine Learning in Predicting Features Related to Congenital Nystagmus. In *IFMBE Proceedings: Vol. Volume 76* (pp. 943–949).
- Gloria Vanessa Urquiza Flores. (2022). *Detección de Anomalías en el Comportamiento de Una Persona*.

- Gordo, R., Marcolin, G., Fuentes, V., Lucero, N., Lucero, C., & Buonanotte, C. F. (2018). Reflejos patológicos. *Neurología Argentina*, 10(3), 147–154. <https://doi.org/10.1016/j.neuarg.2018.05.002>
- Héctor A. González-Usigli. (2022). *Enfermedad de Parkinson*. <https://www.msmanuals.com/es/professional/trastornos-neurol%C3%B3gicos/trastornos-del-movimiento-y-cerebelosos/enfermedad-de-parkinson>
- Hochreiter, S., & Schmidhuber, J. (1996). Bridging long time lags by weight guessing and “Long Short-Term Memory.” In *Spatiotemporal Models in Biological and Artificial Systems*.
- Iberdrola. (2023). ¿QUÉ ES LA INTELIGENCIA ARTIFICIAL? <https://www.iberdrola.com/innovacion/que-es-inteligencia-artificial>
- Instituto Nacional de Neurología y Neurocirugía (INNN). (2017, August 14). *Enfermedad de Parkinson*. <http://www.innn.salud.gob.mx/interna/medica/padecimientos/parkinson.html>
- Kim, Y. S., Lee, J.-H., & Gahm, J. K. (2022). Automated Differentiation of Atypical Parkinsonian Syndromes Using Brain Iron Patterns in Susceptibility Weighted Imaging. *Diagnostics*, 12(3), 637. <https://doi.org/10.3390/diagnostics12030637>
- Lawrence R. Lusting. (2021). *Nistagmo*. MSD. <https://www.msmanuals.com/es/professional/trastornos-otorrinolaringol%C3%B3gicos/trastornos-del-o%C3%ADdo-interno/nistagmo?query=nistagmo>
- Lin, J., Zhang, L., Cao, B., Wei, Q., Ou, R., Hou, Y., Xu, X., Liu, K., Gu, X., & Shang, H. (2021). Abnormal eye movements in spinocerebellar ataxia type 3. *BMC Neurology*, 21(1). <https://doi.org/10.1186/s12883-021-02057-3>
- Liu, W., Lin, X., Chen, X., Wang, Q., Wang, X., Yang, B., Cai, N., Chen, R., Chen, G., & Lin, Y. (2023). Vision-based estimation of MDS-UPDRS scores for quantifying Parkinson’s disease tremor severity. *Medical Image Analysis*, 85, 102754. <https://doi.org/10.1016/j.media.2023.102754>
- López-Rosado Ana Dorado, M.-G. A. T.-P. P. (2018). Aproximación diagnóstica en nistagmus en edad pediátrica. In *Protocolos (diagnósticos y terapéuticos) Aproximación diagnóstica en nistagmus en edad pediátrica: Vol. XLVII* (pp. 151–176).
- Magesh, P. R., Myloth, R. D., & Tom, R. J. (2020). An Explainable Machine Learning Model for Early Detection of Parkinson’s Disease using LIME on DaTSCAN Imagery. *Computers in Biology and Medicine*, 126, 104041. <https://doi.org/10.1016/j.compbiomed.2020.104041>
- María José Jiménez Aguilar. (2021). *DESIGN OF AN IMAGE-BASED SCREENING CLASSIFIER FOR EARLY DETECTION OF PARKINSON’S DISEASE COMPATIBLE PATIENTS USING [18F]PR04.MZ PET TRACER*. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas.
- MedlinePlus. (2023). *Nistagmo*. <https://medlineplus.gov/spanish/ency/article/003037.htm>
- Moscovich, M., Okun, M. S., Favilla, C., Figueroa, K. P., Pulst, S. M., Perlman, S., Wilmot,

- G., Gomez, C., Schmahmann, J., Paulson, H., Shakkottai, V., Ying, S., Zesiewicz, T., Kuo, S. H., Mazzoni, P., Bushara, K., Xia, G., Ashizawa, T., & Subramony, S. H. (2015a). Clinical evaluation of eye movements in spinocerebellar ataxias: A prospective multicenter study. *Journal of Neuro-Ophthalmology*, *35*(1), 16–21. <https://doi.org/10.1097/WNO.000000000000167>
- Newman, J. L., Phillips, J. S., Cox, S. J., FitzGerald, J., & Bath, A. (2019). Automatic nystagmus detection and quantification in long-term continuous eye-movement data. *Computers in Biology and Medicine*, *114*. <https://doi.org/10.1016/j.compbiomed.2019.103448>
- Nunes, A. S., Kozhemiako, N., Stephen, C. D., Schmahmann, J. D., Khan, S., & Gupta, A. S. (2022). Automatic Classification and Severity Estimation of Ataxia From Finger Tapping Videos. *Frontiers in Neurology*, *12*. <https://doi.org/10.3389/fneur.2021.795258>
- Pasquini, J., Ceravolo, R., Qamhawi, Z., Lee, J.-Y., Deuschl, G., Brooks, D. J., Bonuccelli, U., & Pavese, N. (2018). Progression of tremor in early stages of Parkinson's disease: a clinical and neuroimaging study. *Brain*, *141*(3), 811–821. <https://doi.org/10.1093/brain/awx376>
- Pfister, F. M. J., Taewoong Um, T., Pichler, D. C., Goschenhofer, J., Abedinpour, K., Lang, M., Endo, S., Ceballos-Baumann, A. O., Hirche, S., Bischl, B., Kulić, D., & Fietzek, U. M. (n.d.). *High-Resolution Motor State Detection in parkinson's Disease Using convolutional neural networks*. <https://doi.org/10.1038/s41598-020-61789-3>
- Raposo, M., Vasconcelos, J., Bettencourt, C., Kay, T., Coutinho, P., & Lima, M. (2014). *Nystagmus as an early ocular alteration in Machado-Joseph disease (MJD/SCA3)*. <http://www.biomedcentral.com/1471-2377/14/17>
- Reis, D., Kupec, J., Hong, J., & Daoudi, A. (2023). *Real-Time Flying Object Detection with YOLOv8*. <http://arxiv.org/abs/2305.09972>
- Ronnachai Jaroensri, A. Z. D. L. J. D. S. M. D. , F. D. J. G. (2017). A Video-Based Method for Automatically Rating Ataxia. *Machine Learning*, *68*.
- Rosini, F., Pretelegiani, E., Battisti, C., Dotti, M. T., Federico, A., & Rufa, A. (2020). Eye movement changes in autosomal dominant spinocerebellar ataxias. In *Neurological Sciences* (Vol. 41, Issue 7, pp. 1719–1734). Springer. <https://doi.org/10.1007/s10072-020-04318-4>
- Stephen, C. D., & Schmahmann, J. D. (2019). Eye Movement Abnormalities Are Ubiquitous in the Spinocerebellar Ataxias. *Cerebellum*, *18*(6), 1130–1136. <https://doi.org/10.1007/s12311-019-01044-2>
- Stoean, C., Stoean, R., Atencia, M., Abdar, M., Velázquez-Pérez, L., Khosravi, A., Nahavandi, S., Rajendra Acharya, U., & Joya, G. (2020). Automated detection of presymptomatic conditions in spinocerebellar ataxia type 2 using monte carlo dropout and deep neural network techniques with electrooculogram signals. *Sensors (Switzerland)*, *20*(11). <https://doi.org/10.3390/s20113032>
- Tassew, T., Xuan, N., & Bosong, C. (2022). *PDDS: A Software for the Early Diagnosis of Parkinson's Disease from MRI and DatScan Images using Detection and Segmentation Algorithms*. <https://doi.org/10.21203/rs.3.rs-2185967/v1>

- Trabassi, D., Serrao, M., Varrecchia, T., Ranavolo, A., Coppola, G., De Icco, R., Tassorelli, C., & Castiglia, S. F. (2022). Machine Learning Approach to Support the Detection of Parkinson's Disease in IMU-Based Gait Analysis. *Sensors*, 22(10). <https://doi.org/10.3390/s22103700>
- Venegas, P., Millán, M. E., & Miranda, M. (2003). Disquinesia tardía. *Revista Chilena de Neuro-Psiquiatría*, 41(2). <https://doi.org/10.4067/S0717-92272003000200007>
- Virameteekul, S., & Bhidayasiri, R. (2022). We Move or Are We Moved? Unpicking the Origins of Voluntary Movements to Better Understand Semivoluntary Movements. *Frontiers in Neurology*, 13. <https://doi.org/10.3389/fneur.2022.834217>
- Williams, S., Relton, S. D., Fang, H., Alty, J., Qahwaji, R., Graham, C. D., & Wong, D. C. (2020). Supervised classification of bradykinesia in Parkinson's disease from smartphone videos. *Artificial Intelligence in Medicine*, 110, 101966. <https://doi.org/10.1016/j.artmed.2020.101966>
- Zeng, W., Yuan, C., Wang, Q., Liu, F., & Wang, Y. (2019). Classification of gait patterns between patients with Parkinson's disease and healthy controls using phase space reconstruction (PSR), empirical mode decomposition (EMD) and neural networks. *Neural Networks*, 111, 64–76. <https://doi.org/10.1016/j.neunet.2018.12.012>
- Zhang, Z., Hong, R., Lin, A., Su, X., Jin, Y., Gao, Y., Peng, K., Li, Y., Zhang, T., Zhi, H., Guan, Q., & Jin, L. (2021). Automated and accurate assessment for postural abnormalities in patients with Parkinson's disease based on Kinect and machine learning. *Journal of NeuroEngineering and Rehabilitation*, 18(1), 169. <https://doi.org/10.1186/s12984-021-00959-4>
- Zhe Liu. (2017, October 20). *Deep Gray Matter (DGM) Segmentation using 3D Convolutional Neural Network: application to QSM*. <https://towardsdatascience.com/deep-gray-matter-dgm-segmentation-using-neural-network-application-to-qsm-a0183cb3e3ae>
- Zhu, Y., Zheng, S., Yang, G., Fu, X., Xiao, N., Wen, A., Wang, Y., & Zhao, Y. (2020). A novel method for 3D face symmetry reference plane based on weighted Procrustes analysis algorithm. *BMC Oral Health*, 20(1). <https://doi.org/10.1186/s12903-020-01311-3>


# Anexos

## Anexo A

### Movimiento involuntario

El área motora suplementaria (SMA por sus siglas en inglés), es la encargada de tomar la decisión de moverse, así como el orden y la secuencia de los movimientos. El córtex premotor selecciona principalmente los movimientos basándose en información externa proveniente de los córtices sensoriales primarios, la cual, a su vez, es transferida al córtex parietal y al córtex premotor respectivamente (Virameteekul & Bhidayasiri, 2022).

El circuito parieto-premotor-corteza motora primaria (PPCM) está involucrado cuando las acciones motoras dependen de señales externas, es decir, cuando las acciones están dirigidas por estímulos sensoriales. Estos 2 sistemas están normalmente balanceados, permitiendo a las personas saludables realizar movimientos cotidianos sin esfuerzo, pero sin tocar o reaccionar a cada objeto de su entorno. Toda esta información es pasada a la corteza motora a través de los ganglios basales y el cerebelo para chequear y modular el control motor. Luego, debe ser transmitido nuevamente a la corteza motora, pasando por el tálamo. Finalmente, PPCM envía el mensaje final para la ejecución del movimiento motor a algunas estructuras subcorticales, como el núcleo reticular, el núcleo vestibular, el núcleo rojo y las motoneuronas espinales, obteniendo como resultado la realización del movimiento voluntario (Virameteekul & Bhidayasiri, 2022). La figura A.1 muestra cómo es que se origina la intención del movimiento en el cerebro.



**Figura A.1** Circuito de movimiento voluntario originado en el cerebro (Virameteekul & Bhidayasiri, 2022).

## Anexo B

### Movimiento involuntario típico

Sir Charles Scott Sherrington (1857-1952), considerado el padre de la neurociencia actual, planteó que el reflejo es la unidad más simple de la integración neuronal. Propuso una clasificación fisiológica de los tipos de reflejos los cuales serían divididos en exteroceptivos e interoceptivos, a estos últimos, a su vez, los dividió en viscerosceptivos y propioceptivos. Un ejemplo clásico de reflejo sería retirar el brazo cuando se siente dolor, así como cerrar los ojos cuando se realiza un ademán de golpear la cara o cuando se estornuda.

Los reflejos patológicos son aquellos que se producen de manera secundaria a una lesión en el sistema nervioso. Pueden ser superficiales o profundos y es importante analizarlos porque a través de su identificación en el sujeto o paciente, se puede llegar a un diagnóstico de un posible trastorno del movimiento u otra condición médica (Gordo et al., 2018). Algunos ejemplos de reflejos patológicos pueden ser los siguientes:

- *Reflejo de Flatau*: Es la presencia de dilatación pupilar producida por flexión brusca del cuello. Se encuentra presente en casos de irritación meníngea, como en meningitis y hemorragia subaracnoidea.
- *Signo de Lázaro*: Mediante la flexión de la cabeza o con un estímulo doloroso sobre el esternón, se desencadena una secuencia de movimientos, que consisten en una flexión bilateral de los brazos, aducción de los hombros y la extensión de las manos sobre el pecho o el cuello. Pueden presentarse posturas distónicas de los dedos. Se lo observa en pacientes con muerte cerebral.
- *Reflejo de defensa de Remak*: Al rascar la piel en la cara anterior del muslo se produce la flexión plantar del pie y los dedos. Es un reflejo de automatismo medular al producirse una lesión severa de la médula espinal (Gordo et al., 2018).


## Anexo C

### Trastornos del Movimiento

Dentro de este grupo de enfermedades se encuentran el Parkinson, la ataxia y el nistagmo. A continuación, se explican cada una de ellas.

### Parkinson

El Parkinson es un desorden neurodegenerativo, progresivo y crónico. Aparece en el individuo cuando este experimenta la pérdida de los niveles normales de dopamina en la sustancia negra del cerebro. Esta dopamina es un neurotransmisor involucrado en el control del movimiento y se encuentra dentro del circuito de los ganglios basales (ver figura C.1). Algunos de los síntomas característicos de esta enfermedad son los temblores, la lentitud en los movimientos (bradicinesia), la rigidez muscular, deterioro de la postura y el equilibrio, así como cambios en la forma de hablar (Ahrichs & Lawo, 2013).



**Figura C.2** Circuito de los ganglios basales y otras sustancias involucradas en el movimiento (Zhe Liu, 2017).



Debido a estas características de la enfermedad, la calidad de vida se ve afectada por un número mayor de síntomas no motores (por ejemplo, depresión, trastornos del sueño, anormalidades cognitivas/neuroconductuales, disfunción autonómica y gastrointestinal). A medida que la enfermedad avanza, los síntomas del paciente cambian y fluctúan (es decir, algunos síntomas simplemente desaparecen, mientras que otros reaparecen), creando una historia sintomática única para cada paciente individual (Ahlich & Lawo, 2013).

El síntoma de "Tremor" en reposo (conocido como temblor de reposo o temblor en estado de reposo) está presente solamente cuando los músculos están en reposo y desaparece durante el sueño, así como con el movimiento voluntario de la extremidad afectada (Carissimo et al., 2022). Se manifiesta como un temblor involuntario y unilateral de una extremidad (mano o el pie). El temblor generalmente ocurre a una frecuencia entre 4-7 Hz, está presente en el 70% de los pacientes con Parkinson y suele desaparecer con la realización de un movimiento voluntario (Pasquini et al., 2018).

El temblor postural (PT, por sus siglas en inglés) se produce cuando una parte del cuerpo se mantiene recta hacia fuera del cuerpo en una posición estable contra la gravedad. Por lo general se refiere a la cabeza o las extremidades. Ocurre en las frecuencias de 5-8 Hz (Carissimo et al., 2022). Por otra parte, el temblor cinético surge cuando se realiza una acción contrayendo voluntariamente el músculo. Este tipo de temblor causa una mayor discapacidad que las otras clasificaciones y ocurre a una frecuencia de 9 Hz (Dai et al., 2015).

La "Brdicinesia" se refiere a la lentitud del movimiento. Por lo general, aparece en las etapas muy tempranas de la enfermedad y es característica de los trastornos de los ganglios basales. Dependiendo de la gravedad, los movimientos no solo pueden ser lentos, sino también disminuidos (hipocinesia) o completamente suprimidos (acinética) (Ahlich & Lawo, 2013).

El "Congelamiento de la marcha" (FOG, por sus siglas en inglés) también conocido como congelamiento o bloqueos motores, es una forma de acinesia que se presenta como una incapacidad para iniciar o continuar el movimiento. Los bloqueos motores son un síntoma común experimentado por los pacientes (aunque no ocurre uniformemente) y pueden afectar varias extremidades, así como la cara. Después del inicio de esta característica, tiende a durar varios segundos y desaparece posteriormente. Es una causa común de caídas (Ahlich & Lawo, 2013).

Desafortunadamente, en una etapa avanzada de la enfermedad de Parkinson, pueden aparecer más síntomas inducidos por fármacos. La discinesia es uno de estos y resulta de un tratamiento farmacológico prolongado por varios años. Se manifiesta como un

movimiento involuntario de partes completas del cuerpo (por ejemplo, movimiento rítmico del cuerpo superior).

Algunos tipos de discinesias son las siguientes:

- *Distonías*. Son contracciones musculares involuntarias, que resultan en movimientos de torsión repetitivos y posturas anormales.
- *Corea*. Está caracterizada por un flujo constante de movimientos involuntarios, bruscos y breves, que pueden cambiar de una zona a otra del cuerpo de forma incierta e impredecible.
- *Mioclonias*. Son movimientos breves, rápidos y bruscos, a modo de sacudidas, y con una amplitud variable.
- *Discinesia tardía*. Es un tipo de movimiento involuntario y anormal que se origina tras un mínimo de 3 meses de uso de medicamentos o fármacos neurolépticos, sin que exista otra causa identificable. Incluye el movimiento anómalo de la lengua, los labios y la mandíbula, además de gestos como el chupeteo, la succión y la masticación repetitiva, irregular y estereotipadamente (*Discinesias, 2023*)

Los fármacos involucrados en la génesis de una discinesia tardía son variados, aunque los más frecuentes son aquellos que intervienen con la transmisión dopaminérgica. Las distintas clases de fármacos incluyen antipsicóticos, bloqueadores de canales de calcio, inhibidores de la recaptación de serotonina, antidepresivos tricíclicos, anticonvulsivantes, antiarrítmicos, proquinéticos intestinales y otros (Venegas et al., 2003).

Los tratamientos actuales están enfocados en ralentizar la progresión de la enfermedad, centrarse en el alivio sintomático e intentar aliviar la enorme carga de la enfermedad de Parkinson. Sin embargo, todavía no se ha encontrado una cura (Ahlich & Lawo, 2013).

## **Ataxia**

La ataxia es un trastorno del movimiento caracterizado por la falta de coordinación en los movimientos musculares. Este signo clínico es provocado por la degeneración variable de neuronas en la corteza cerebelosa, tronco cerebral, vías espinocerebelosas y sus conexiones aferentes y eferentes (Carrera-González et al., 2017). Las ataxias se clasifican en dos categorías principales: las adquiridas y las heredadas, siendo éstas últimas las más comunes y estudiadas debido a la base genética que poseen.

De acuerdo con el patrón de herencia, las ataxias heredadas se dividen en autosómicas recesivas y autosómicas dominantes (Carrera-González et al., 2017). Las ataxias

autosómicas dominantes son generalmente conocidas como ataxias espinocerebelosas (SCAs, del inglés Spinocerebellar Ataxias) y comprenden un grupo de trastornos neurodegenerativos hereditarios que se caracterizan por su heterogeneidad clínica, patológica y genética.

Clínicamente, la SCA2 se caracteriza por la presencia de una ataxia progresiva en la marcha, enlentecimiento de los movimientos oculares sacádicos que evoluciona en una oftalmoplejía, temblores posturales y cinéticos, contracturas musculares dolorosas de los miembros inferiores (mioclonos) e hiporeflexia. Adicionalmente, se reportan otros síntomas como desorden del sueño y neuropatía periférica axonal de tipo sensitiva (Carrera-González et al., 2017). Pueden estar presente también otras características como la marcha inestable o con los pies muy separados, equilibrio reducido, mala coordinación, dificultad con tareas de motricidad fina, como comer, escribir o abotonarse una camisa. En algunas personas se ha visto que presentan una dificultad para tragar, así como cambios en la forma de hablar (disartria), siendo este un síntoma compartido en el caso del Parkinson.

Los movimientos oculares anormales son comunes en las ataxias espinocerebelosas, incluyendo el seguimiento suave impedido, aumento de los sacudimientos en forma de onda cuadrada (SWJ), nistagmo provocado por la mirada (GEN), ralentización de las sacadas, hipo/hipermetría sacádica y parálisis supranuclear de la mirada (Rosini et al., 2020; Stephen & Schmahmann, 2019). En el artículo de (Lin et al., 2021) reporta que algunos estudios se han centrado en el potencial papel distintivo de los movimientos oculares anormales entre los subtipos de SCA. En otras investigaciones, se afirma que los movimientos oculares anormales son frecuentes en pacientes con SCA3 (Moscovich et al., 2015). Por ejemplo, se ha informado que el nistagmo está presente en el 88% de los pacientes con SCA3 (Raposo et al., 2014).

En la investigación de (Rosini et al., 2020) reporta que hasta esa fecha se habían identificado aproximadamente 50 tipos clínicamente diferentes de ataxias e identificado 37 genes asociados a esta enfermedad. Entre ellos, SCA1, 2, 3, 6, 7 y 17 son expansiones de repetición CAG en el ADN que codifican una extensión de poliglutamina dentro de la proteína correspondiente. SCA8, 10 y 12 se deben a expansiones de repetición no traducidas en regiones no codificantes de los genes. SCA5, SCA13, SCA14, SCA27 y la SCA adjunta al cromosoma 16q22 están relacionadas con mutaciones puntuales. La SCA4 y la SCA asociada al cromosoma 16q22 han sido asignadas a la misma región cromosómica, pero no se han encontrado mutaciones en la familia original de la SCA4.

Destaca además que la ausencia de antecedentes familiares no descarta una ataxia genética. Los familiares mayores que llevan la mutación pueden no haber desarrollado

completamente los síntomas o pueden estar clínicamente sin afectación. Planteó que se observó que muchas ataxias genéticas comparten un mecanismo similar de causación de la enfermedad. En particular, las expansiones de poliglutamina se asocian con la desregulación transcripcional, debido al deterioro del sistema ubiquitina-proteasoma y el proceso de autofagia, responsable de la degradación y eliminación de proteínas mal plegadas o superfluas y que lleva a la agregación de proteínas. Otros posibles mecanismos de causación de la enfermedad son la malformación de proteínas que resulta en una función alterada, la formación de complejos oligoméricos tóxicos, disfunción mitocondrial, transporte axonal deteriorado, excitotoxicidad, deterioro de la homeostasis de proteínas celulares y toxicidad de ARN (Rosini et al., 2020).

La presentación clínica es extremadamente heterogénea. Los hallazgos clínicos comunes suelen incluir una presentación de inicio tardío, típicamente alrededor de la tercera o cuarta década, el síndrome cerebeloso de progresión lenta con diversas combinaciones de trastornos oculomotores, disartria, dismetría/tremor cinético y/o marcha atáxica. El diagnóstico a menudo se complica por la posible concomitancia de retinopatía pigmentaria, trastornos extrapiramidales y diversos trastornos del movimiento (parkinsonismo, discinesias, distonía, corea), signos piramidales, síntomas corticales (convulsiones, deterioro cognitivo/síntomas conductuales) y neuropatía periférica (Rosini et al., 2020).

Algunos síntomas clínicos pueden proporcionar una pista para abordar el diagnóstico. En este sentido, la ataxia cerebelosa pura es típica de SCA6, la oftalmoplejía es bastante específica de SCA28 y la ralentización prominente de los movimientos sacádicos es característica de SCA2; la retinopatía pigmentaria se ve generalmente en SCA7. La espasticidad puede encontrarse en SCA3. Las discinesias y cambios de comportamiento son típicos de SCA17 y DRPLA; las convulsiones se observan con frecuencia en SCA10, SCA17 y DRPLA.

## **Nistagmo**

El nistagmo es un trastorno ocular caracterizado por movimientos rápidos e involuntarios de los ojos que pueden ser de un lado a otro (nistagmo horizontal), de arriba hacia abajo (nistagmo vertical) y rotatorio (nistagmo de torción). Este trastorno puede afectar la visión, el equilibrio y la coordinación. La anomalía aparece debido a un mal funcionamiento de las áreas del cerebro que controlan los movimientos de los ojos. Existen varias clasificaciones para el nistagmo. Entra ellas se encuentran según la edad de inicio:

*Síndrome de nistagmo infantil.* Está presente al nacer (congénito) o antes de los 6 meses de vida.

*Nistagmo adquirido.* Se presenta posteriormente en la vida debido a una

enfermedad o lesión (MedlinePlus, 2023)

También existe la clasificación según la causa:

- *Nistagmus fisiológicos*. Se consideran normales. Se denominan:
  1. Optocinético. Se produce al seguir los objetos en movimiento.
  2. De la mirada extrema. Es un nistagmus en resorte, simétrico y de baja amplitud que se produce cuando los ojos se mueven hacia lateroversiones (inclinaciones) extremas en algunas personas.
  3. Vestibular inducido. Estimulando el laberinto (oído interno) al rotar la cabeza o por irrigación del conducto auditivo externo.
  
- *Nistagmus patológicos*. Debidos a lesiones a nivel ocular y/o neurológicas. Algunos son:
  1. *Síndrome de nistagmus infantil*. Aparece antes de los 6 meses de edad, con mayor frecuencia sobre los 2-3 meses de edad. Suele ser binocular, conjugado y horizontal en el 77% de las ocasiones u horizontal-torsional, pero, aunque es raro, puede tener un componente vertical. Se mantiene en dirección horizontal en todas las posiciones de la mirada, a diferencia del nistagmus adquirido y/o el vestibular que aun siendo horizontal cambia a vertical en la mirada vertical (López-Rosado Ana Dorado, 2018).
  2. *Síndrome de Spasmus Mutans*. Se manifiesta con cabeceo, nistagmus y tortícolis y se resuelve espontáneamente en 1-2 años en la mayoría de los casos.
  3. *Nistagmus vestibular*. Tiene un componente lento causado por el estímulo vestibular y un componente rápido, correctivo, que provoca el movimiento en la dirección opuesta. La dirección del nistagmo está definida por la del componente rápido porque es más fácil de observar. El nistagmo puede ser rotatorio, vertical u horizontal y suceder de modo espontáneo, con la mirada o con el movimiento de la cabeza (Lawrence R. Lusting, 2021).

## Anexo E

### Red LSTM

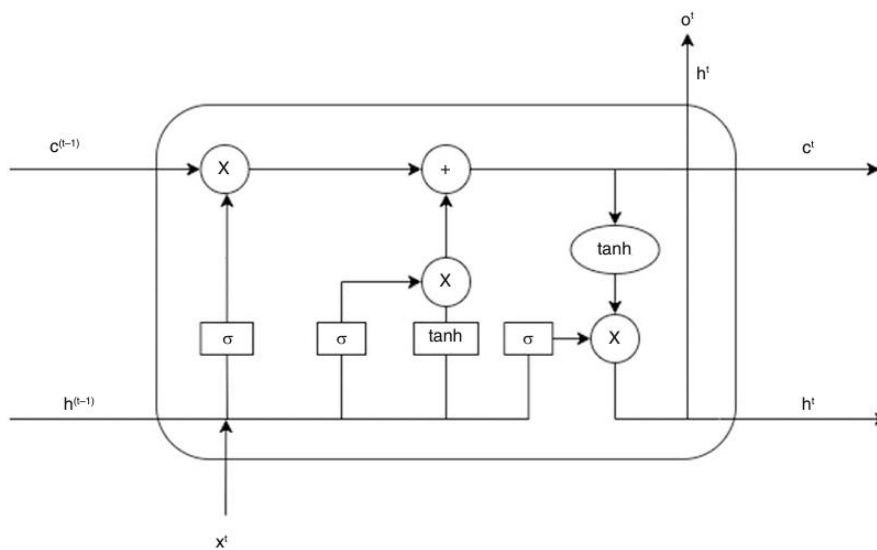
Las redes de memoria a corto y largo plazo (LSTM) son un tipo de red neuronal recurrente propuesta en 1997 (Das et al., 2023). Estas redes resuelven el problema de la propagación del error de un instante de tiempo  $t$  hasta uno anterior que puede estar bastante lejano en la red. En este tipo de red, la unidad base se llama celda de memoria. Dentro de cada una de ellas, existe una unidad lineal con una autoconexión de peso fijo. Esta estructura garantiza un flujo de error constante, evitando explosiones o desapariciones del error (Hochreiter & Schmidhuber, 1996)

### Estructura de la LSTM

Una LSTM consta de una recurrencia externa como una RNN ordinaria y un bucle interno que permite que los gradientes fluyan durante más tiempo, dependiendo del contexto en lugar de ser fijos. Cada celda de la LSTM contiene un sistema de unidades de puertas que controla el flujo de información. Dichas puertas principales son:

- **Puerta de entrada:** Decide qué información de entrada es relevante para guardar en la memoria a largo plazo.
- **Puerta de olvido:** Determina qué información almacenada en la memoria a largo plazo debe ser descartada.
- **Puerta de salida:** Controla qué parte de la información almacenada debe ser utilizada para calcular la salida.

La figura E.1 muestra la estructura de dicha red.



**Figura E.3** Arquitectura de la red LSTM, en ella se encuentra la celda de estado  $C$ , el estado oculto  $h$ , la entrada  $x$ , así como la salida  $o$  (Das et al., 2023)

## Funcionamiento de las compuertas

Las compuertas son redes neuronales que funcionan como válvulas las que totalmente abiertas permiten el paso de la información y si están cerradas bloquean el flujo de datos. Cada una de las compuertas están conformadas por una red neuronal, una función sigmoide y un elemento multiplicador. Dichas compuertas o *gates* son:

**Puerta de Olvido (f):** Usa una función sigmoide para determinar si se debe retener o descartar la información del estado de la celda. Después de aplicada la función sigmoide, si el valor es cercano a 0 se descarta la información, si es cercano a 1 dicho dato se mantiene hasta que llega a la celda de estado. La ecuación para esta compuerta es la siguiente:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Los parámetros  $w_f$  y  $b_f$  son los pesos recurrentes y el *bias* respectivamente,  $x_t$  denota el vector de entrada en el tiempo  $t$ .

**Puerta de Entrada (x):** Similar a la puerta de olvido, pero decide qué nueva información debe ser almacenada.

**Puerta de actualización (u):** Actualiza elementos de la memoria de la celda. Se preservan en la memoria de la red los valores cercanos a 1. La fórmula de esta compuerta es la siguiente:

$$u_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

Acto seguido, se procede a actualizar la memoria de la celda de estado, dado que se han obtenido los valores de las compuertas  $f_t$  y  $u_t$ . Para actualizar dicha celda, se elimina la información irrelevante, creando previamente un vector de valores candidatos de la forma:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

Luego se realiza el filtrado, multiplicando punto a punto los vectores  $u_t$  y  $\tilde{C}_t$  para después aplicar la fórmula:

$$c_t = f_t \cdot c_{t-1} + u_t \cdot \tilde{c}_t \quad (4)$$

De esta forma se genera la memoria actualizada.

**Puerta de Salida (o):** Controla la información que sale de la celda de memoria. Es decir, crea el estado oculto actualizado. Constituye una versión filtrada de la celda actualizada  $c_t$ . Primeramente, se realiza un escalado de la forma  $\tanh(c_t)$ , luego se emplea la compuerta  $o_t$  para determinar qué porciones de la celda de estado formarán parte del nuevo estado oculto.

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

Finalmente se obtiene la salida de la forma:

$$h_t = O_t \cdot \tanh(c_t) \quad (6)$$

Las ecuaciones de las puertas se representan matemáticamente para calcular los estados internos y las salidas, donde  $\sigma$  denota la función sigmoide y  $\tanh$  la función

tangente hiperbólica. Los parámetros  $W$  y  $b$  con sus subíndices correspondientes son aprendidos durante la etapa de entrenamiento.

### **Ventajas de la red**

La LSTM puede manejar el problema del gradiente que desaparece mediante las puertas que controlan el flujo de información, lo que permite que las características importantes del pasado se retengan y no se sobrescriban con nueva información.

### **Aplicaciones**

La capacidad de LSTM para recordar dependencias a largo plazo la hace adecuada para tareas como el reconocimiento de voz, la traducción de idiomas y la generación de subtítulos para imágenes. Además, la LSTM se usa para resolver problemas complejos que no pueden ser manejados eficientemente por otros algoritmos de redes neuronales recurrentes.



## Anexo F

### Perceptrón multicapa

El perceptrón multicapa (MLP por sus siglas en inglés) es una red neuronal artificial que consta de una capa de entrada, una o más capas ocultas y una capa de salida. Cada neurona en una capa está conectada a todas las neuronas de la siguiente capa, formando una estructura de red completamente conectada. Las neuronas reciben señales de entrada, las procesan mediante una función de activación no lineal y transmiten la salida a las neuronas de la siguiente capa. Esta arquitectura permite al MLP aprender y modelar relaciones complejas y no lineales en los datos, superando las limitaciones del perceptrón simple, que solo puede manejar problemas linealmente separables (Gardner, 1998).

El entrenamiento del MLP se realiza mediante un algoritmo llamado retro propagación del error (*backpropagation*), que ajusta los pesos de las conexiones neuronales para minimizar la diferencia entre las salidas predichas y las reales. Este proceso implica dos fases principales: en la propagación hacia adelante, los datos de entrada se transmiten a través de la red para generar una predicción; en la retro propagación, el error de la predicción se calcula y se propaga hacia atrás a través de la red, ajustando los pesos en consecuencia. Este método iterativo permite al MLP aprender de los datos y mejorar su precisión en tareas como clasificación, regresión y reconocimiento de patrones.

## Anexo G

### Constancias de participación

A continuación, se presentan las constancias de participación en diferentes eventos donde se abordó el tema de investigación.



**Figura G.4** Constancia de participación en el evento de inteligencia computacional y robótica, con poster relacionado con la investigación.



**Figura G.2** Constancia de participación en el evento del coloquio de inteligencia artificial 2024, con poster relacionado con la investigación.

**EL TECNOLÓGICO NACIONAL DE MÉXICO  
A TRAVÉS DEL CENTRO NACIONAL DE INVESTIGACIÓN  
Y DESARROLLO TECNOLÓGICO**

OTORGA EL PRESENTE

**RECONOCIMIENTO**

A

**Darlen Calcedo Aguirre, Raúl Pinto Elías, Andrea Magadán  
Salazar, Nimrod González Franco**

Por su destacada participación con la presentación del Artículo  
en el área Ciencias de la Computación, eje estratégico Seguridad Humana y Salud titulado:  
Identificación de patrones atípicos en personas con movimientos involuntarios  
En el marco del 3er Congreso Internacional de Tecnología y Ciencias Aplicadas (CITCA), celebrado en el  
Tecnológico Nacional de México, campus Centro Nacional de Investigación y Desarrollo Tecnológico  
(TecNM/CENIDET), del 19 al 22 de noviembre de 2024

Cuernavaca, Morelos, 22 de noviembre de 2024



CITCA54624  
<http://investacion.cenidet.tecnm.mx>

**LORENZO O. HERNÁNDEZ**  
DIRECTOR DEL CENTRO NACIONAL DE  
INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO

**ALICIA MARTÍNEZ REBOLLAR**  
COORDINADORA GENERAL  
III CITCA

Sello Digital:

cs3N7p2f260zr3xg1cR1nLn0PyYS2vYGFw0kCjY8y4h8NTgymz2wTeQ45PjESJqz9pXomRCRTx0MewFRlygkQ  
0VFNXCJ1g6H4No/FTF-xcNk4Uy+HvQClVxunG2sVJTx135e8z5wCnBt1T5280QW6ugSecKniVUeahKY3FX8Y  
vdt+7Bwg09Lzjpv37YcvkYDmKHPExtIamh0pP3X0a0urJ70cFB0V1009LgMfu122g5kymsz2qJFSRY08E0ac8  
rny10V3h0qKt0827BF6Ngb2Z0ku+y5G5SRV7YVQW6Q4e64u0P/E3F-dq50k207554462m50FV7bJL1D5t9k==



**Figura G.3** Constancia de participación en el evento de CITCA 2024, con una ponencia relacionada con el tema de investigación.