



# Educación

Secretaría de Educación Pública



TECNOLÓGICO  
NACIONAL DE MÉXICO®  
Instituto Tecnológico de Orizaba

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

**“Desarrollo de un módulo de software para la  
detección temprana de la enfermedad de Parkinson  
mediante técnicas de Procesamiento de  
Lenguaje Natural”**

QUE PARA OBTENER EL GRADO DE:

**MAESTRO EN SISTEMAS  
COMPUTACIONALES**

PRESENTA:


*I.S.C. Justo Francisco León  
Pastor Baak*

DIRECTOR DE TESIS:

*Dr. Giner Alor Hernández*

CODIRECTOR DE TESIS:

*M.S.C. Nancy Aracely Cruz Ramos*



ORIZABA, VERACRUZ, MÉXICO.

NOVIEMBRE 2025



**Educación**  
Secretaría de Educación Pública



TECNOLÓGICO  
NACIONAL DE MÉXICO



**Instituto Tecnológico de Orizaba**  
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, **4/noviembre/2025**  
Dependencia: **División de Estudios de**  
**Posgrado e Investigación**  
Asunto: **Autorización de Impresión**  
OPCION: I

**C. JUSTO FRANCISCO LEÓN PASTOR BAAK**  
**CANDIDATO A GRADO DE MAESTRO EN:**  
**SISTEMAS COMPUTACIONALES**  
**P R E S E N T E.-**


De acuerdo con el Reglamento de Titulación vigente de los Centros de Enseñanza Técnica Superior, dependiente de la Dirección General de Institutos Tecnológicos de la Secretaría de Educación Pública y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

**" Desarrollo de un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de Procesamiento de Lenguaje Natural"**

comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

**ATENTAMENTE**  
*Excelencia en Educación Tecnológica®*  
CIENCIA - TÉCNICA - CULTURA®

  
**DRA. OFELIA LANDETA ESCAMILLA**  
**JEFA DE LA DIVISIÓN DE ESTUDIOS**  
**DE POSGRADO E INVESTIGACIÓN**



OG-13-F06



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

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320  
Orizaba, Veracruz. Tel. 01 (272) 1105360  
e-mail: [info@orizaba.tecnm.mx](mailto:info@orizaba.tecnm.mx) [www.orizaba.tecnm.mx](http://www.orizaba.tecnm.mx)





**Educación**  
Secretaría de Educación Pública



TECNOLÓGICO  
NACIONAL DE MÉXICO



**Instituto Tecnológico de Orizaba**  
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, **19/marzo/2025**  
Asunto: **Revisión de trabajo escrito**

**C. OFELIA LANDETA ESCAMILLA**  
**JEFA DE LA DIVISIÓN DE ESTUDIOS**  
**DE POSGRADO E INVESTIGACIÓN**  
**P R E S E N T E.-**

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.

**JUSTO FRANCISCO LEÓN PASTOR BAAK**

La cual lleva el título de:

**Desarrollo de un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de Procesamiento de Lenguaje Natural**

Y concluyen que se acepta.

**ATENTAMENTE**

Excelencia en Educación Tecnológica®  
CIENCIA - TÉCNICA - CULTURA®

PRESIDENTE: DR. GINER ALOR HERNÁNDEZ  
SECRETARIO: DR. JOSÉ LUIS SÁNCHEZ CERVANTES  
VOCAL: DRA. LISBETH RODRÍGUEZ MAZAHUA  
VOCAL SUP.: M.S.C. NANCY ARACELY CRUZ RAMOS

FIRMA

FIRMA

FIRMA

FIRMA

TA-09-18



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

Av. Oriente 9 #852 Colonia Emiliano Zapata, C.P. 94320  
Orizaba, Veracruz. Tel. 01 (272) 1105360  
e-mail: [info@orizaba.tecnm.mx](mailto:info@orizaba.tecnm.mx) [www.orizaba.tecnm.mx](http://www.orizaba.tecnm.mx)



## **CARTA DE ORIGINALIDAD**

En la ciudad de Orizaba, Veracruz, el día 14 del mes de noviembre del año 2025, el (la) que suscribe Justo Francisco León Pastor Baak, alumno (a) del programa de Maestría en Sistemas Computacionales con número de control M22011021, manifiesta que es autor (a) del trabajo de tesis titulado "Desarrollo de un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de procesamiento de lenguaje natural" y declara que el trabajo es original, ya que su contenido es producto de su directa contribución intelectual. Todos los datos y las referencias a materiales ya publicados están debidamente identificados con su respectivo crédito e incluidos en las notas bibliográficas y en las citas que se destacan como tal y, en los casos que así lo requieran, se tienen las debidas autorizaciones de quienes poseen los derechos patrimoniales. Por lo tanto, se hace responsable de cualquier litigio o reclamación relacionada con derechos de propiedad intelectual, exonerando de toda responsabilidad al Tecnológico Nacional de México / Instituto Tecnológico de Orizaba.



---

Justo Francisco León Pastor Baak

## SECRETARÍA DE EDUCACIÓN PÚBLICA – TECNOLÓGICO NACIONAL DE MÉXICO

Por medio del presente documento, reconocemos que el programa de cómputo **“PARKINSONAPP: MÓDULO DE SOFTWARE PARA LA DETECCIÓN TEMPRANA DE LA ENFERMEDAD DE PARKINSON MEDIANTE TÉCNICAS DE PROCESAMIENTO DE LENGUAJE NATURAL”** fue realizado de conformidad con las actividades laborales y con la normatividad aplicable en la **SECRETARÍA DE EDUCACIÓN PÚBLICA -TECNOLÓGICO NACIONAL DE MÉXICO**, por lo que admitimos, en términos del artículo 46 del Reglamento de la Ley Federal del Derecho de Autor y en concordancia con el artículo 83 de la Ley Federal del Derecho de Autor, que la titularidad de los derechos patrimoniales y las facultades relativas a la divulgación, integridad del programa de cómputo y de colección sobre este tipo de creaciones, corresponden a la Federación, a través de la Secretaría de Educación Pública -Tecnológico Nacional de México.

Asimismo, relevamos de toda responsabilidad a la **Secretaría de Educación Pública - Tecnológico Nacional de México** de cualquier demanda o reclamación que llegara a formular alguna persona física o moral que se considere con derecho sobre el programa de cómputo **“PARKINSONAPP: MÓDULO DE SOFTWARE PARA LA DETECCIÓN TEMPRANA DE LA ENFERMEDAD DE PARKINSON MEDIANTE TÉCNICAS DE PROCESAMIENTO DE LENGUAJE NATURAL”** asumiendo todas las consecuencias jurídicas o legales y económicas si ésta no fuese de nuestra creación.

### PROTESTAMOS LO NECESARIO

Firma: \_\_\_\_\_

Nombre: Justo Francisco León Pastor Baak.

Participación: 20%.

Firma: \_\_\_\_\_

Nombre: Nancy Aracely Cruz Ramos.

Participación: 20%.

Firma: \_\_\_\_\_

Nombre: Lisbeth Rodríguez Mazahua

Participación: 20%.

Firma: \_\_\_\_\_

Nombre: Giner Alor Hernández.

Participación: 20%.

Firma: \_\_\_\_\_

Nombre: José Luis Sánchez Cervantes.

Participación: 20%.

## **Agradecimientos**

Agradezco profundamente a todos aquellos que formaron parte de este camino académico y personal durante la realización de mi maestría. A mi madre, la maestra Ana María Pastor Baak García, por su apoyo incondicional a lo largo de toda mi vida, por su ejemplo de fortaleza y dedicación, y por ser siempre mi mayor inspiración a Rubén Álvarez Castillo, por ser un ejemplo a seguir en muchos aspectos de mi vida y por las enseñanzas que han dejado una marca significativa en mi formación, a mis abuelos, la maestra Lourdes Guerrero García y el señor Justo Pastor Baak Tzuc, quienes me inculcaron disciplina, bondad y amor por el conocimiento. Su ejemplo ha guiado mis decisiones y mi carácter, a Alondra Martínez Nieves, por su apoyo y compañía en los momentos clave.

Agradezco al Dr. Giner Alor Hernández, por su exigencia, orientación y por ayudarme a corregir mis errores con firmeza y sabiduría, a la maestra Nancy Araecli Cruz Ramos, por mostrarme el lado humano y profesional de esta maestría, así como por su comprensión y acompañamiento constante, a la maestra Betty, por sus valiosos consejos y la paciencia que nos brindó durante todo el proceso formativo, al Dr. José Luis Sánchez Cervantes, por su carácter relajado, directo y motivador, que me impulsó a esforzarme más cada día, a mis compañeros de generación, por su apoyo, por los trabajos en equipo, los días de esfuerzo compartido, los aprendizajes, y por esos frapes que nos ayudaron a sobrellevar las jornadas más pesadas. Su dedicación y constancia me motivaron a no quedarme atrás y a mejorar continuamente, a mis hermanas, por estar siempre presentes en mi vida y brindarme su cariño y motivación, al Dr. Humberto, por aconsejarme dar este paso e impulsarme a ingresar a la maestría.

Agradezco a mis fieles compañeros de cuatro patas, Max y Zirga, quienes con su presencia y compañía hicieron más llevaderos los largos días y noches de estudio. A todos ustedes, gracias por ser parte fundamental de este logro.

Finalmente, agradezco al Consejo Nacional de Humanidades Ciencias y Tecnologías (CONAHCYT) por el apoyo económico otorgado y al Tecnológico Nacional de México (TecNM) por dar soporte a esta investigación.

# ÍNDICE GENERAL

|                                                                             |      |
|-----------------------------------------------------------------------------|------|
| ÍNDICE GENERAL .....                                                        | III  |
| ÍNDICE DE FIGURAS .....                                                     | V    |
| ÍNDICE DE TABLAS .....                                                      | VIII |
| RESUMEN .....                                                               | X    |
| INTRODUCCIÓN .....                                                          | 1    |
| CAPÍTULO 1. ANTECEDENTES .....                                              | 2    |
| 1.1 Marco teórico.....                                                      | 2    |
| 1.1.1 Enfermedad neurodegenerativa .....                                    | 2    |
| 1.1.1.1 Tipos de enfermedades neurodegenerativas .....                      | 2    |
| 1.1.2 Enfermedad de Parkinson.....                                          | 4    |
| 1.1.3 Inteligencia artificial.....                                          | 5    |
| 1.1.4 Procesamiento de lenguaje natural .....                               | 6    |
| 1.1.4.1 Técnicas de procesamiento de lenguaje natural.....                  | 7    |
| 1.1.4.2 Bibliotecas de funciones de procesamiento de lenguaje natural ..... | 8    |
| 1.1.4.3 Data sets para la detección de Parkinson por voz .....              | 9    |
| 1.2 Situación tecnológica, económica y operativa de la empresa .....        | 14   |
| 1.3 Planteamiento del problema .....                                        | 14   |
| 1.4 Objetivo general y objetivos específicos .....                          | 15   |
| 1.4.1 Objetivo general .....                                                | 15   |
| 1.4.2 Objetivos específicos .....                                           | 16   |
| 1.5 Justificación .....                                                     | 16   |
| CAPÍTULO 2. ESTADO DE LA PRÁCTICA .....                                     | 19   |
| 2.1 Trabajos relacionados .....                                             | 19   |
| 2.2 Análisis comparativo .....                                              | 30   |
| 2.3 Solución propuesta .....                                                | 33   |
| 2.3.1 Tecnologías del entorno de desarrollo y despliegue.....               | 33   |
| 2.3.1.1 Visual Studio Code.....                                             | 33   |

|                                                                                |           |
|--------------------------------------------------------------------------------|-----------|
| 2.3.1.2 Docker Desktop .....                                                   | 33        |
| 2.3.2 Tecnologías de la capa de presentación e integración .....               | 34        |
| 2.3.2.1 TypeScript .....                                                       | 34        |
| 2.3.2.2 Angular .....                                                          | 34        |
| 2.3.2.3 IONIC .....                                                            | 34        |
| 2.3.2.4 PHP .....                                                              | 34        |
| 2.3.3 Tecnologías de la capa de servicios .....                                | 35        |
| 2.3.3.1 Python .....                                                           | 35        |
| 2.3.3.2 FastAPI .....                                                          | 36        |
| 2.3.3.3 Scikit-Learn .....                                                     | 36        |
| 2.3.4 Tecnologías de la capa de persistencia .....                             | 36        |
| 2.3.4.1 MySQL .....                                                            | 36        |
| 2.3.5 Justificación de la solución .....                                       | 37        |
| <b>CAPÍTULO 3. APLICACIÓN DE LA METODOLOGÍA .....</b>                          | <b>38</b> |
| 3.1 Análisis .....                                                             | 38        |
| 3.1.1 Requerimientos .....                                                     | 39        |
| 3.1.2 Casos de uso .....                                                       | 39        |
| 3.1.3 Características de la aplicación .....                                   | 44        |
| 3.1.4 Conjunto de datos de atributos de voz para la detección de EP .....      | 45        |
| 3.1.5 Selección de algoritmos de clasificación .....                           | 46        |
| 3.2 Fase de Diseño .....                                                       | 51        |
| 3.2.1 Arquitectura del módulo .....                                            | 51        |
| 3.2.2 Modelo de persistencia .....                                             | 54        |
| 3.2.2.1 Diccionario de datos .....                                             | 55        |
| 3.2.3 Maquetación del modulo .....                                             | 60        |
| 3.2.3.1 Componentes personalizados .....                                       | 60        |
| 3.2.3.2 Inicio de sesión .....                                                 | 63        |
| 3.3 Desarrollo .....                                                           | 70        |
| 3.3.1 Reglas para determinar el pronóstico de la enfermedad de Parkinson ..... | 70        |
| 3.3.2 Módulo de pruebas .....                                                  | 71        |
| 3.3.3 Implementación de los algoritmos de clasificación .....                  | 71        |

|                                                                              |           |
|------------------------------------------------------------------------------|-----------|
| 3.3.4 Implementación del módulo .....                                        | 74        |
| <b>CAPÍTULO 4. RESULTADOS .....</b>                                          | <b>82</b> |
| 4.1 Casos de estudio: Detección temprana de la Enfermedad de Parkinson ..... | 82        |
| 4.1.1 Caso de estudio 1: Paciente con pronóstico poco probable .....         | 82        |
| 4.1.2 Caso de estudio 2: Paciente con pronóstico altamente probable .....    | 83        |
| 4.1.3 Caso de estudio 3: Paciente con pronóstico probable.....               | 83        |
| 4.1.4 Datos iniciales .....                                                  | 83        |
| 4.1.5 Clasificación automática de datos .....                                | 83        |
| 4.1.6 Resultados.....                                                        | 84        |
| <b>CAPÍTULO 5. CONCLUSIONES .....</b>                                        | <b>90</b> |
| 5.1 Recomendaciones .....                                                    | 90        |
| <b>PRODUCTOS ACADÉMICOS .....</b>                                            | <b>92</b> |
| <b>CAPÍTULO 6.....</b>                                                       | <b>92</b> |
| 6.1 Artículo de congreso.....                                                | 92        |
| 6.1.1 PDF publicación del artículo .....                                     | 93        |
| 6.2 Retribución social .....                                                 | 94        |
| 6.3 Poster y video .....                                                     | 95        |
| <b>BIBLIOGRAFÍA .....</b>                                                    | <b>96</b> |

## Índice de figuras

|                                                                                                                            |    |
|----------------------------------------------------------------------------------------------------------------------------|----|
| <i>Figura 1.1. Enfermedades neurodegenerativas más comunes. [Elaboración propia]</i> .....                                 | 3  |
| <i>Figura 1.2. Algoritmo de NLP. [Elaboración propia]</i> .....                                                            | 6  |
| <i>Figura 1.3 Conjunto de datos de la Universidad de Oxford [10]</i> .....                                                 | 10 |
| <i>Figura 1.4. Conjunto de datos de Parkinson con características acústicas replicadas [13].</i> ..                        | 11 |
| <i>Figura 1.5. Conjunto de datos de biomarcadores tempranos de la EP basados en el habla natural conectada [15].</i> ..... | 12 |
| <i>Figura 1.6. Conjunto de datos del habla de Parkinson con múltiples tipos de grabaciones de sonido [16].</i> .....       | 13 |
| <i>Figura 1.7. Conjunto de datos de clasificación de la EP [18].</i> .....                                                 | 14 |
| <i>Figura 3.1 Metodología de desarrollo.</i> .....                                                                         | 38 |
| <i>Figura 3.2 Diagrama de casos de uso del contexto Ejercicios.</i> .....                                                  | 40 |
| <i>Figura 3.3 Diagrama de casos de uso del contexto Pronóstico.</i> .....                                                  | 42 |
| <i>Figura 3.4 Arquitectura del módulo web para la detección temprana de la Enfermedad de Parkinson.</i> .....              | 52 |
| <i>Figura 3.5 Esquema relacional de base de datos.</i> .....                                                               | 54 |
| <i>Figura 3.6 Mockup – Componente – Encabezado</i> .....                                                                   | 60 |
| <i>Figura 3.7 Mockup - Componente - Menú lateral.</i> .....                                                                | 60 |
| <i>Figura 3.8 Mockup - Componente - Tarjeta concepto.</i> .....                                                            | 61 |
| <i>Figura 3.9 Mockup - Componente - Tarjeta estadística.</i> .....                                                         | 61 |
| <i>Figura 3.10 Mockup – Componente – Tarjeta de gráfico.</i> .....                                                         | 62 |
| <i>Figura 3.11 Mockup - Componente - Tarjeta de gráfico compacto.</i> .....                                                | 62 |
| <i>Figura 3.12 Mockup - Componente - Tarjeta de datos.</i> .....                                                           | 63 |
| <i>Figura 3.13 Mockup - Interfaz de inicio de sesión.</i> .....                                                            | 63 |
| <i>Figura 3.14 Mockup - Interfaz de panel estadístico (Principal)</i> .....                                                | 65 |
| <i>Figura 3.15 Mockup -Interfaz de pacientes (Registros de los pacientes)</i> .....                                        | 66 |
| <i>Figura 3.16 Mockup - Interfaz de los ejercicios realizados por el paciente.</i> .....                                   | 66 |
| <i>Figura 3.17 Interfaz de la historia de pronósticos del paciente.</i> .....                                              | 67 |
| <i>Figura 3.18 Interfaz de los detalles de los ejercicios de la prueba.</i> .....                                          | 67 |
| <i>Figura 3.19 Mockup - Interfaz - Ejercicio de fonación.</i> .....                                                        | 69 |

|                                                                                    |    |
|------------------------------------------------------------------------------------|----|
| <i>Figura 3.20 Mockup - Interfaz - Ejercicio de lectura de texto.</i>              | 69 |
| <i>Figura 3.21 Mockup -Interfaz - Ejercicio de lectura de texto.</i>               | 70 |
| <i>Figura 3.22 Rangos para determinar el pronóstico de Parkinson.</i>              | 70 |
| <i>Figura 3.23 Respuesta JSON del módulo de pruebas.</i>                           | 71 |
| <i>Figura 3.24 Flujo operacional para la clasificación de ejercicios.</i>          | 74 |
| <i>Figura 3.25 Interfaz de inicio de sesión</i>                                    | 74 |
| <i>Figura 3.26 Interfaz principal.</i>                                             | 75 |
| <i>Figura 3.27 Interfaz de ejercicios realizados.</i>                              | 75 |
| <i>Figura 3.28 Interfaz de historial del paciente</i>                              | 76 |
| <i>Figura 3.29 Interfaz de los detalles de los ejercicios de la prueba.</i>        | 77 |
| <i>Figura 3.30 Interfaz de catálogo de ejercicios de voz.</i>                      | 77 |
| <i>Figura 3.31 Interfaz del menú de selección de vocal.</i>                        | 78 |
| <i>Figura 3.32 Interfaz del ejercicio de fonación de la vocal a.</i>               | 78 |
| <i>Figura 3.33 Interfaz del menú de selección de lectura.</i>                      | 79 |
| <i>Figura 3.34 Interfaz del ejercicio de lectura 1.</i>                            | 80 |
| <i>Figura 3.35 Interfaz del ejercicio de repetición de palabras.</i>               | 81 |
| <i>Figura 4.1 Selección del tipo de ejercicio.</i>                                 | 84 |
| <i>Figura 4.2 Módulo web - Aplicación del ejercicio de fonación de vocal.</i>      | 85 |
| <i>Figura 4.3 Módulo web - Aplicación del ejercicio de lecturas de texto.</i>      | 85 |
| <i>Figura 4.4 Módulo web - Aplicación del ejercicio de repetición de palabras.</i> | 86 |
| <i>Figura 4.5 Interfaz pacientes.</i>                                              | 86 |
| <i>Figura 4.6 Interfaz del historial de ejercicios.</i>                            | 87 |
| <i>Figura 4.7 Interfaz del modal para la selección de ejercicios.</i>              | 88 |
| <i>Figura 4.8 Interfaz del resultado de pronóstico.</i>                            | 88 |

## Índice de tablas

|                                                                                                                             |    |
|-----------------------------------------------------------------------------------------------------------------------------|----|
| Tabla 2.1 Análisis comparativo de los artículos relacionados.....                                                           | 30 |
| Tabla 3.1 Atributos en el conjunto de datos Parkinson Data Set. ....                                                        | 45 |
| Tabla 3.2 Comparación de las métricas de los algoritmos implementados en el conjunto de<br>datos Parkinson's Data Set. .... | 48 |
| Tabla 3.3 Resultados de la curva ROC.....                                                                                   | 49 |
| Tabla 3.4 Diccionario de entidad "PARKINSON.TIPOS.EJERCICIOS" .....                                                         | 55 |
| Tabla 3.5 Diccionario de entidad "PARKINSON.TIPOS.PRUEBAS" .....                                                            | 55 |
| Tabla 3.6 Diccionario de entidad "PARKINSON.CAT.EJERCICIOS" .....                                                           | 56 |
| Tabla 3.7 Diccionario de entidad "PARKINSON.PROC.PRUEBAS" .....                                                             | 57 |
| Tabla 3.8 Diccionario de entidad "PARKINSON.PROC.DETALLES_PRUEBAS" .....                                                    | 57 |
| Tabla 3.9 Diccionario de entidad "PRUEBAS_DETALLES" .....                                                                   | 59 |
| Tabla 3.10 Diccionario de entidad "USUARIOS.REL.PACIENTES_CUIDADORES" .....                                                 | 59 |
| Tabla 3.11 Diccionario de entidad "USUARIOS_REL.PACIENTES_MEDICOS" .....                                                    | 59 |
| Tabla 4.1 Valores de referencia para la identificación de Parkinson. ....                                                   | 84 |

## **Índice de listados**

|                                                                                                                                      |           |
|--------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <i>Listado 3-1 Código de implementación para el proceso de entrenamiento el modelo de clasificación Support Vector Machine. ....</i> | <i>72</i> |
| <i>Listado 3-2 Código de implementación para endpoint POST /predict .....</i>                                                        | <i>73</i> |

## **Resumen**

La enfermedad de Parkinson, una condición neurodegenerativa prevalente, representa un reto importante debido a su complejidad y la falta de herramientas eficaces para la detección temprana. Los síntomas abarcan tanto aspectos motores como no motores, lo que genera una carga significativa para los pacientes, sus familias y la sociedad. En respuesta a esta necesidad, surge una propuesta de software para la detección temprana de la enfermedad mediante un enfoque accesible y no invasivo que aprovecha tecnologías de Procesamiento del Lenguaje Natural.

El módulo permite al paciente realizar fonaciones de vocales, lecturas de texto y repeticiones de palabras para ser grabadas, almacenadas en audios, que luego son procesados por algoritmos de Procesamiento de Lenguaje Natural entrenados específicamente para identificar patrones vocales asociados con el Parkinson. Esta tecnología facilita la identificación temprana de síntomas antes de que se manifiesten los signos motores clásicos de la enfermedad, permitiendo una intervención oportuna que mejora la calidad de vida de los afectados. Entre las tecnologías empleadas destacan Python, herramientas de reconocimiento de voz, la combinación de estas tecnologías ofrece una base sólida y actualizada para el desarrollo de este sistema de detección temprana de la enfermedad de Parkinson.

Algunos beneficios clave de esta herramienta incluyen: detectar de forma anticipada los síntomas iniciales, lo que abre la puerta a tratamientos más efectivos, utilizando un método no invasivo que, al basarse en el análisis de la voz, evita procedimientos médicos costosos y potencialmente intimidantes para el paciente, además esta herramienta contribuye a aumentar la conciencia sobre la enfermedad promoviendo la educación acerca de sus síntomas y la relevancia de un diagnóstico temprano con una precisión del 89.00% en el pronóstico de su predicción.

## **Abstract**

Parkinson's disease, a prevalent neurodegenerative condition, represents a major challenge due to its complexity and the lack of effective tools for early detection. Symptoms encompass both motor and non-motor aspects, which generates a significant burden for patients, their families and society. In response to this need, a software proposal arises for the early detection of the disease through an accessible and non-invasive approach that leverages Natural Language Processing technologies.

The module allows the patient to make vowel phonations, text readings and word repetitions to be recorded, stored in audios, which are then processed by Natural Language Processing algorithms specifically trained to identify vowel patterns associated with Parkinson's disease. This technology facilitates the early identification of symptoms before the classic motor signs of the disease manifest themselves, enabling timely intervention that can improve the quality of life of those affected. The technologies employed include Python and voice recognition tools. The combination of these technologies provides a solid and up-to-date foundation for the development of this early detection system for Parkinson's disease.

Some key benefits of this tool include: early detection of early symptoms, which opens the door to more effective treatments, using a non-invasive method that, by relying on voice analysis, avoids costly and potentially intimidating medical procedures for the patient, in addition this tool contributes to increase awareness of the disease by promoting education about its symptoms and the relevance of early diagnosis with an 89.00% accuracy in its prognostic prediction.

## Introducción

La enfermedad de Parkinson, es una enfermedad neurodegenerativa que afecta a millones globalmente, caracterizada por la disminución de dopamina, crucial para el control del movimiento, con síntomas como temblores, rigidez muscular y problemas del habla, su progresión es gradual y sin cura conocida, aunque existen tratamientos para aliviar síntomas, debido a que la longevidad contemporánea ha elevado la incidencia de enfermedades neurodegenerativas, en respuesta, se ha planteado el desarrollo de un software de detección temprana de Parkinson, utilizando algoritmos de procesamiento de lenguaje natural para analizar características vocales. Este enfoque ofrece un pronóstico anticipado, crucial para iniciar tratamientos y mejorar la calidad de vida. El presente trabajo propone el desarrollo de un módulo de software el cual se desarrolló en cuatro etapas; El análisis de los algoritmos y técnicas de Procesamiento de Lenguaje Natural para la extracción de elementos vocales, y así pronosticar en etapas tempranas de la enfermedad de Parkinson; El diseño de una arquitectura de software y un conjunto de prestaciones de servicio para el desarrollo del módulo de software para la identificación temprana de la enfermedad de Parkinson; El desarrollo de un módulo de software para la identificación temprana de la enfermedad de Parkinson mediante técnicas de procesamiento de lenguaje natural; y la evaluación y validación del módulo de software a través de un conjunto de casos de estudio como prueba de concepto.

La estructura de esta tesis está conformada por el capítulo 1; contiene los antecedentes de la investigación comenzado por el marco teórico con las definiciones de Enfermedad neurodegenerativa, enfermedad de Parkinson, Inteligencia Artificial, Procesamiento de Lenguaje Natural, bibliotecas para el Procesamiento del Lenguaje Natural, conjuntos de datos, también se incluye el planteamiento del problema, objetivo general, objetivos específicos, y la justificación para la realización del presente trabajo. El capítulo 2; abarca el estado del arte englobando los trabajos más relacionados con el análisis de los algoritmos y técnicas de Procesamiento de Lenguaje Natural para la extracción de elementos vocales para la detección de la temprana de la enfermedad de Parkinson, en capítulo 3; especifica la descripción de la solución propuesta para el desarrollo del módulo sobre la detección de la enfermedad de Parkinson, en el capítulo 4: describe los resultados obtenidos por los diferentes casos de estudio y por último el capítulo 5: las conclusiones.

## **Capítulo 1. Antecedentes**

En este capítulo, se presentan los conceptos más importantes, la problemática a resolver, el objetivo general, los objetivos específicos y la justificación.

### **1.1 Marco teórico**


A continuación, se describen términos relacionados con el tema de investigación.

#### **1.1.1 Enfermedad neurodegenerativa**

De acuerdo con Cummings *et al.* [1] las enfermedades neurodegenerativas se caracterizan por un síndrome clínico distintivo de déficits neurológicos, cambios del comportamiento, declive funcional progresivo y trastornos motores, respaldados por una pérdida neuronal inexorable que es patológica para la edad del sujeto, incluyen una serie de enfermedades cerebrales (con o sin participación de la médula espinal) caracterizadas por el deterioro progresivo de la función cerebral y la pérdida de las actividades de la vida diaria. Las enfermedades neurodegenerativas comprenden la enfermedad de Alzheimer, la enfermedad de Parkinson, la demencia frontotemporal, la demencia con cuerpos de Lewy, la encefalopatía traumática crónica, la atrofia de múltiples sistemas, la parálisis supranuclear progresiva, la degeneración corticobasal, la enfermedad de Huntington, la esclerosis lateral amiotrófica, las ataxias progresivas entre otras enfermedades.

##### **1.1.1.1 Tipos de enfermedades neurodegenerativas**

Las enfermedades neurodegenerativas son un grupo diverso de trastornos que afectan al sistema nervioso y se caracterizan por la degeneración progresiva de las células nerviosas, de acuerdo con Bradley y Walter [2], su diagnóstico consiste en la serie de pasos en la que, el neurólogo recopila datos (la tarea), con el objeto de proporcionar información sobre la localización anatómica y la naturaleza del proceso de la enfermedad (el objetivo), existen varios tipos de enfermedades neurodegenerativas, como se muestran en la figura 1.1.



*Figura 1.1. Enfermedades neurodegenerativas más comunes. [Elaboración propia]*

**Enfermedad de Alzheimer:** Se caracteriza por la acumulación de placas de proteína beta-amiloide y ovillos neurofibrilares en el cerebro, lo que lleva a la pérdida de memoria y deterioro cognitivo. Es la forma más común de demencia en adultos mayores.

**Enfermedad de Parkinson:** Implica la degeneración de las células dopaminérgicas en el cerebro, lo que conduce a problemas de movimiento, temblores, rigidez muscular y otros síntomas motores.

**Enfermedad de Huntington:** Se hereda de forma autosómica dominante y se caracteriza por movimientos anormales, cambios en la personalidad y deterioro cognitivo, su causa es una expansión anormal del gen HTT.

**Esclerosis lateral amiotrófica:** Es una enfermedad que afecta a las neuronas motoras, provocando debilidad muscular progresiva y deterioro motor, también se conoce como la enfermedad de Lou Gehrig.

**Esclerosis múltiple:** Es una enfermedad crónica del sistema nervioso central que afecta el cerebro y la médula espinal. Se trata de una enfermedad autoinmune, lo que significa que el sistema inmunológico del cuerpo ataca de manera errónea el tejido sano del sistema nervioso central. Esto daña la mielina, una sustancia que recubre y protege las fibras nerviosas en el cerebro y la médula espinal.

**Demencia de cuerpos de Lewy:** Esta enfermedad se caracteriza por la acumulación de proteínas alfa-sinucleína en el cerebro. Los síntomas incluyen alucinaciones visuales, fluctuaciones en la cognición y problemas motores similares a los de la PD.

### 1.1.2 Enfermedad de Parkinson

Martínez *et al.* Definen la enfermedad de Parkinson como “un proceso neurodegenerativo complejo de aparición en la edad adulta y que constituye la segunda enfermedad neurodegenerativa más frecuente por detrás de la demencia tipo Alzheimer. Su etiología es desconocida y, en términos generales, la causa subyacente sería una combinación de factores ambientales y genéticos. Su base anatomopatológica se caracteriza por la pérdida progresiva de neuronas dopaminérgicas de la sustancia negra compacta del mesencéfalo, así como la presencia de inclusiones intracelulares llamadas cuerpos de Lewy, que están formados por agregados insolubles de proteína alfa-sinucleína anormalmente plegada. El resultado de dicha neurodegeneración es la denervación dopaminérgica de las proyecciones de la sustancia negra dopaminérgica compacta hacia el núcleo estriado, lo que condiciona una alteración en la

fisiología normal de los ganglios basales que origina las principales manifestaciones de la enfermedad” [3].

Los síntomas abarcan síntomas motores como temblores, bradicinesia, rigidez, inestabilidad postural, deterioro cognitivo, bradifenía, hiponimia, disartria, disfagia, sialorrea, depresión, apatía, anhedonia, fatiga, y otros [4]. En la actualidad existe evidencia que sugiere que la enfermedad no afecta la sustancia negra dopaminérgica compacta en las etapas más tempranas, sino que comienza en el tronco encefálico inferior, el bulbo y el núcleo olfatorio anterior. La participación temprana de áreas no relacionadas con el sistema nigroestriatal resalta la importancia de evaluar síntomas que incluyen estreñimiento, trastornos del sueño, anomia, y así sucesivamente. No solo estos y otros rasgos no motores se vuelven más comunes y problemáticos a medida que progresa la enfermedad, sino que algunos también sirven como marcadores tempranos de la presencia de la enfermedad, incluso antes de que se desarrollen características parkinsonianas más típicas, reconocer y evaluar estos rasgos se vuelve particularmente importante. De acuerdo con Bradley y Walter [2], los afectados por enfermedad de Parkinson presentan los siguientes desórdenes del discurso y lenguaje: mudez, afasia, velocidad rápida, volumen reducido, monótono y mono sonoridad, disartria hipocinética, tartamudeo adquirido.

### 1.1.3 Inteligencia artificial

De acuerdo con Rouhiainen [5], la inteligencia artificial (IA) es la capacidad de las máquinas para usar algoritmos, aprender de los datos y utilizar lo aprendido en la toma de decisiones tal y como lo haría un ser humano. Sin embargo, a diferencia de las personas, los dispositivos basados en IA no necesitan descansar y analizar grandes volúmenes de información a la vez. Asimismo, la proporción de errores es significativamente menor en las máquinas que realizan las mismas tareas que sus contrapartes humanas, esta definición permite entender el alcance de sus aplicaciones, en cuanto a la aplicación de la IA en el lenguaje humano Russell *et al.* [6] mencionan que comprender el lenguaje natural como el Inglés o Español, es definirlo como un modelo del lenguaje natural, como una probabilidad de distribución sobre sentencias, los

lenguajes naturales también son ambiguos y finalmente son difíciles de tratar porque son muy largos y en constante cambio.

#### 1.1.4 Procesamiento de lenguaje natural

El trabajo de Cole y otros menciona que los lenguajes naturales son diferentes de los lenguajes de programación de computadoras. No están destinados a traducirse en un conjunto finito de operaciones matemáticas, como lo están los lenguajes de programación. El Procesamiento de Lenguaje Natural (PLN), es una rama de la inteligencia artificial que se centra en la interacción entre las computadoras y el lenguaje humano. Su objetivo es permitir que las máquinas comprendan, interpreten y generen lenguaje humano de manera efectiva [7]. La manera en que trabaja el PLN comienza con la recopilación de datos, en donde una computadora se alimenta por una cantidad masiva de datos de entrenamiento, para después entrenar el modelo de PLN donde se etiquetan estos datos con reglas de lenguaje y se aplican técnicas de PLN, después se utilizan algoritmos de aprendizaje automático, a continuación, los entrenadores calibran el modelo con retroalimentación de refuerzo, en la figura 1.2. se muestra el algoritmo de PLN.

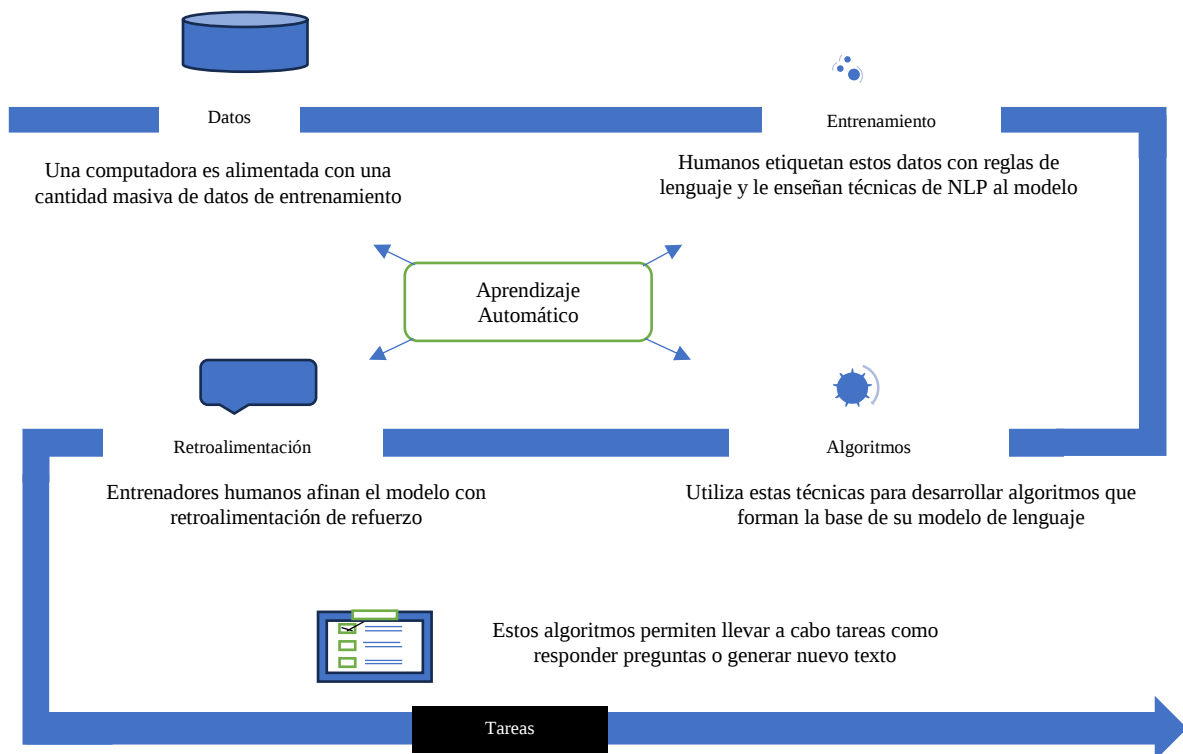


Figura 1.2. Algoritmo de NLP. [Elaboración propia]

#### 1.1.4.1 Técnicas de procesamiento de lenguaje natural

Las técnicas de PLN son métodos y enfoques utilizados para manipular y analizar texto y lenguaje humano de manera automática. Estas técnicas permiten a las computadoras entender, interpretar y generar lenguaje natural, como el inglés, español o cualquier otro idioma. Algunas de las técnicas más comunes en el procesamiento del lenguaje natural son:

**Segmentación de texto:** Se refiere al proceso de dividir un texto más largo en unidades más pequeñas o segmentos, como oraciones, párrafos o palabras, con el fin de facilitar su análisis, procesamiento y comprensión. La segmentación de texto es una tarea fundamental en el Procesamiento del Lenguaje Natural y se utiliza en una variedad de aplicaciones, como el análisis de sentimientos, la traducción automática, la extracción de información y el resumen de textos.

**Segmentación por oraciones:** Dividir un texto en oraciones individuales es una forma común de segmentación de texto. Esto se realiza utilizando reglas gramaticales y señales de puntuación, como puntos, comas y signos de exclamación. También se utilizan modelos de lenguaje pre-entrenados para esta tarea.

**Segmentación por párrafos:** En algunos casos, es útil dividir un texto en párrafos para identificar secciones temáticas o estructuradas organizativas. Esto se hace mediante la detección de saltos de línea o mediante análisis estructural.

**Segmentación por palabras:** La segmentación de texto por palabras implica dividir un texto en sus unidades más pequeñas, es decir, palabras. Esto es útil para análisis lingüísticos, como la identificación de las palabras clave en un texto.

**Tokenización:** La tokenización es el proceso de dividir un texto en unidades más pequeñas llamadas *tokens*, como subpalabras o caracteres [8].

**Bolsa de palabras:** Se utiliza para representar y analizar documentos de texto. Esta técnica simplifica el texto al tratar cada documento como una “bolsa” o conjunto de palabras, sin tener en cuenta la estructura gramatical o el orden de las palabras en el documento. El enfoque se basa en la frecuencia de las palabras en el texto y se utiliza en diversas aplicaciones de PLN, como la clasificación de texto, la recuperación de información y la agrupación de documentos.

**Eliminación de *stopwords*:** Las *stopwords* son palabras comunes que a menudo se eliminan del texto durante el procesamiento.

La clasificación en el procesamiento del PLN se refiere a la tarea de asignar una etiqueta, categoría o clase a un texto o documento basándose en su contenido. Esta es una de las tareas fundamentales en PLN y tiene una amplia gama de aplicaciones, como la clasificación de documentos, la detección de spam, la categorización de noticias, la identificación de sentimientos en reseñas de productos entre otras.

**La clasificación binaria:** En la clasificación binaria, el objetivo es dividir los textos en 2 categorías o clases mutuamente excluyentes, como “positivo” o “negativo”, “spam” o “no spam”, “aprobado” o “rechazado”.

**La clasificación multiclase:** En la clasificación multiclase, se asignan múltiples categorías o etiquetas a un texto. Por ejemplo, clasificar noticias en categorías como “política”, “deportes”, “entretenimiento”, entre otros.

En el trabajo de Jurafsky *et al.* [9] mencionan que, para el análisis de fonemas, los humanos y máquinas hacen uso del análisis espectral y para determinados componentes de frecuencia de sonido, el uso de espectrogramas tiene un mejor rendimiento en el análisis de los formantes.

#### 1.1.4.2 Bibliotecas de funciones de procesamiento de lenguaje natural

Las bibliotecas de funciones de PLN por voz son herramientas esenciales en el ámbito de la inteligencia artificial y la interacción hombre máquina basada en voz. Estas bibliotecas, como

*SpeechRecognition*, *CMU Sphinx*, y *Google Cloud Speech-to-Text*, están diseñadas para procesar y comprender el habla humana en forma de voz, lo que permite una amplia gama de aplicaciones, desde asistentes virtuales hasta sistemas de reconocimiento de voz en automóviles. Estas bibliotecas permiten la conversión del habla en texto (reconocimiento de voz) y muchas otras aplicaciones relacionadas con el PLN por voz. Además, algunas de estas bibliotecas también son capaces de trabajar en tiempo real, lo que es fundamental para aplicaciones de interacción en tiempo real, como la atención automatizada al cliente o el control de dispositivos mediante comandos de voz.

Estas herramientas simplifican en gran medida el desarrollo de aplicaciones y servicios que involucren la voz, lo que permite una comunicación más natural y efectiva entre humanos y sistemas computacionales a través de la tecnología del PLN por voz.

#### **1.1.4.3 Data sets para la detección de Parkinson por voz**

Para la detección de PD por voz, es crucial contar con conjuntos de datos (*data sets*) de alta calidad que permitan entrenar y evaluar modelos de aprendizaje automático.

Algunos de ellos son el conjunto de datos de tele monitorización de la enfermedad de Parkinson de Oxford [10], este conjunto de datos se compone 26 atributos enteros y reales, 5875 instancias, que abarcan un rango medidas biomédicas de voz de 42 personas con enfermedad de Parkinson en etapa temprana, las columnas en la tabla contienen un número de sujeto, edad del sujeto, género del sujeto con valores de 0 para el masculino y 1 para el femenino, intervalo de tiempo de la fecha de reclutamiento básico donde la parte entera es el número de días desde el reclutamiento, motor de la Escala unificada para la evaluación de la Enfermedad de Parkinson (UPDRS), UPDRS total, y 16 medidas biomédicas de voz como: temblor, brillo, medidas de ruido hasta los componentes tonales en la voz, medida no lineal de la complejidad dinámica, exponente de escalada fractal de la señal y una medida no lineal de la variación de la frecuencia fundamental, donde cada fila corresponde a 1 de 5,875 grabaciones de voz de estos individuos. El principal objetivo de estos datos es predecir el motor y total del puntaje de la escala UPDRS de las 16 medidas de voz. Los datos están en formato ASCII CSV (*Comma Separated Values*,

Valores separados por coma). Las filas del archivo CSV contienen una instancia correspondiente a una grabación de voz. Hay alrededor de seis grabaciones por paciente, el nombre del paciente se identifica en la primera columna como se muestra en la figura 1.3.

```
subject#,age,sex,test_time,motor_UPDRS,total_UPDRS,Jitter(%),Jitter(Abs),Jitter:RAP,Jitter:PPQ5,Jitter:DDP,Shimmer,Shimmer(dB),s
1,72,0,5.6431,28.199,34.398,0.00662,3.38e-005,0.00401,0.00317,0.01204,0.02565,0.23,0.01438,0.01309,0.01662,0.04314,0.01429,21.64,0.41
1,72,0,12.666,28.447,34.894,0.003,1.68e-005,0.00132,0.0015,0.00395,0.02024,0.179,0.00994,0.01072,0.01689,0.02982,0.011112,27.183,0.43
1,72,0,19.681,28.695,35.389,0.00481,2.462e-005,0.00205,0.00208,0.00616,0.01675,0.181,0.00734,0.00844,0.01458,0.02202,0.02022,23.047,C
1,72,0,25.647,28.905,35.81,0.00528,2.657e-005,0.00191,0.00264,0.00573,0.02309,0.327,0.01106,0.01265,0.01963,0.03317,0.027837,24.445,C
1,72,0,33.642,29.187,36.375,0.00335,2.014e-005,0.00093,0.0013,0.00278,0.01703,0.176,0.00679,0.00929,0.01819,0.02036,0.011625,26.126,C
1,72,0,40.652,29.435,36.87,0.00353,2.29e-005,0.00119,0.00159,0.00357,0.02227,0.214,0.01006,0.01337,0.02263,0.03019,0.009438,22.946,0.
1,72,0,47.649,29.682,37.363,0.00422,2.404e-005,0.00212,0.00221,0.00637,0.04352,0.445,0.02376,0.02621,0.03488,0.07128,0.01326,22.506,C
1,72,0,54.64,29.928,37.857,0.00476,2.471e-005,0.00226,0.00259,0.00678,0.02191,0.212,0.00979,0.01462,0.01911,0.02937,0.027969,22.929,C
1,72,0,61.669,30.177,38.353,0.00432,2.854e-005,0.00156,0.00207,0.00468,0.04296,0.371,0.01774,0.02134,0.03451,0.05323,0.013381,22.078
1,72,0,68.688,30.424,38.849,0.00496,2.702e-005,0.00258,0.00253,0.00773,0.0361,0.31,0.0203,0.0197,0.02569,0.06089,0.018021,22.606,0.50
1,72,0,75.653,30.67,39.34,0.00465,2.553e-005,0.00238,0.0026,0.00715,0.02132,0.188,0.01069,0.01214,0.01844,0.03206,0.017443,25.672,0.4
1,72,0,82.653,30.917,39.834,0.00537,3.216e-005,0.00236,0.00278,0.00709,0.02377,0.282,0.01001,0.01375,0.02395,0.03003,0.017115,24.204
1,72,0,89.635,31.309,40.412,0.00524,3.287e-005,0.00235,0.00251,0.00704,0.02493,0.24,0.01176,0.01395,0.02019,0.03528,0.011876,22.203,C
1,72,0,96.633,31.776,41.034,0.00354,2.388e-005,0.00142,0.0015,0.00427,0.02107,0.171,0.00847,0.0104,0.0192,0.0254,0.015008,24.614,0.61
1,72,0,103.64,32.243,41.657,0.0053,3.181e-005,0.00241,0.00231,0.00724,0.02791,0.291,0.0131,0.0126,0.02069,0.0393,0.018093,23.533,0.51
1,72,0,110.65,32.71,42.28,0.00456,2.908e-005,0.00152,0.00194,0.00457,0.02878,0.264,0.01379,0.01494,0.02309,0.04138,0.020181,22.203,0.
1,72,0,117.66,33.178,42.904,0.00693,3.93e-005,0.00329,0.00285,0.00987,0.0281,0.274,0.01468,0.0143,0.01952,0.04405,0.04198,20.878,0.52
1,72,0,124.64,33.643,43.524,0.00652,3.783e-005,0.00313,0.00311,0.0094,0.03011,0.32,0.01603,0.01733,0.02293,0.0481,0.031634,22.212,0.5
1,72,0,131.64,34.109,44.146,0.00571,3.711e-005,0.00296,0.00293,0.00889,0.02522,0.223,0.0126,0.01466,0.02145,0.0378,0.031546,23.129,0.
1,72,0,139.69,34.646,44.861,0.00372,2.221e-005,0.00181,0.00195,0.00542,0.0323,0.288,0.01458,0.01732,0.02908,0.04373,0.010976,22.939,C
1,72,0,145.64,35.043,45.39,0.00285,1.646e-005,0.00079,0.00109,0.00237,0.01524,0.133,0.00567,0.00682,0.01299,0.01702,0.004652,25.181,C
1,72,0,152.64,35.509,46.013,0.00629,3.574e-005,0.00278,0.00293,0.00835,0.03791,0.338,0.01915,0.02174,0.03315,0.05745,0.043582,20.757
```

Figura 1.3 Conjunto de datos de la Universidad de Oxford [10]

Se utilizó en trabajos de Little *et al.* [11] [12], para medir la disfonía y la detención de desórdenes en la voz.

El conjunto de datos de Parkinson con características acústicas replicadas en el trabajo de Little *et al* [13] contiene características acústicas extraídas de 3 réplicas de grabaciones de voz de la fonación /a/ sostenida de cada uno de los 80 sujetos (40 de ellos con enfermedad de Parkinson), se componen de los atributos ID como identificador del sujeto, *Recording* con el número de la grabación, *State* con valores de 0 para sano y 1 para enfermedad de Parkinson, *Gender* con valores de 0 para hombre y 1 para mujer, medidas de perturbación del tono local como temblor, medidas de perturbación de amplitud como el brillo local, medidas de relación de armónico/ruido, medidas espectrales basadas en el coeficiente cepstral de la frecuencia Mel, entropía de densidad del periodo de recurrencia, análisis de fluctuaciones sin tendencia, entropía

del periodo de tono y la relación de excitación glotal/ruido, los datos se muestran en la figura 1.4.

| ID      | Recording | Status | Gender | Jitter_rel | Jitter_abs | Jitter_RAP | Jitter_PPQ | Shim_loc | St |
|---------|-----------|--------|--------|------------|------------|------------|------------|----------|----|
| CONT-01 | 1         | 0      | 1      | 0.25546    | 1.4581E-05 | 0.001467   | 0.0016734  | 0.030256 |    |
| CONT-01 | 2         | 0      | 1      | 0.36964    | 2.1662E-05 | 0.0019317  | 0.0022446  | 0.023146 |    |
| CONT-01 | 3         | 0      | 1      | 0.23514    | 1.3109E-05 | 0.0013527  | 0.0015465  | 0.019338 |    |
| CONT-02 | 1         | 0      | 0      | 0.2932     | 1.7331E-05 | 0.0011048  | 0.0014443  | 0.024716 |    |
| CONT-02 | 2         | 0      | 0      | 0.23075    | 1.4561E-05 | 0.0010729  | 0.0014043  | 0.013119 |    |
| CONT-02 | 3         | 0      | 0      | 0.16489    | 1.0011E-05 | 0.00081887 | 0.0011912  | 0.010666 |    |
| CONT-03 | 1         | 0      | 1      | 0.22506    | 1.4288E-05 | 0.0013581  | 0.0014599  | 0.017181 |    |
| CONT-03 | 2         | 0      | 1      | 0.23086    | 1.4545E-05 | 0.0013486  | 0.0015459  | 0.017775 |    |
| CONT-03 | 3         | 0      | 1      | 0.22898    | 1.4978E-05 | 0.0013751  | 0.0016073  | 0.02011  |    |
| CONT-04 | 1         | 0      | 1      | 1.31       | 0.00010317 | 0.0082445  | 0.0062801  | 0.030742 |    |
| CONT-04 | 2         | 0      | 1      | 1.0647     | 8.1987E-05 | 0.0062989  | 0.0059491  | 0.023969 |    |
| CONT-04 | 3         | 0      | 1      | 1.0417     | 8.1777E-05 | 0.0060929  | 0.006277   | 0.022837 |    |
| CONT-05 | 1         | 0      | 0      | 0.78955    | 0.00010252 | 0.0042382  | 0.0045742  | 0.039162 |    |
| CONT-05 | 2         | 0      | 0      | 0.5301     | 6.8621E-05 | 0.0023786  | 0.0033674  | 0.034966 |    |
| CONT-05 | 3         | 0      | 0      | 0.48444    | 6.3685E-05 | 0.0022722  | 0.0029482  | 0.032814 |    |
| CONT-06 | 1         | 0      | 1      | 0.40538    | 2.7508E-05 | 0.0023285  | 0.0024892  | 0.015854 |    |
| CONT-06 | 2         | 0      | 1      | 0.41475    | 2.8235E-05 | 0.0023402  | 0.0025758  | 0.022903 |    |
| CONT-06 | 3         | 0      | 1      | 0.548      | 3.7106E-05 | 0.0032687  | 0.0034847  | 0.04794  |    |
| CONT-07 | 1         | 0      | 0      | 0.5282     | 4.7834E-05 | 0.0026782  | 0.0032264  | 0.05588  |    |
| CONT-07 | 2         | 0      | 0      | 0.643      | 6.0469E-05 | 0.0034625  | 0.003797   | 0.046695 |    |
| CONT-07 | 3         | 0      | 0      | 0.45764    | 3.9862E-05 | 0.0024445  | 0.0029431  | 0.040232 |    |
| CONT-08 | 1         | 0      | 1      | 0.58384    | 3.6612E-05 | 0.0033268  | 0.0035481  | 0.04464  |    |

Figura 1.4. Conjunto de datos de Parkinson con características acústicas replicadas [13].

Este conjunto de datos [13] se usó en trabajos como el de Naranjo *et al.* [14] para rastrear la severidad de los síntomas en la enfermedad de Parkinson.

El conjunto de datos de biomarcadores tempranos de la enfermedad de Parkinson basados en el habla natural conectada [15] incluye datos de 30 pacientes con enfermedad de Parkinson temprana no tratada, 50 pacientes con trastorno de conducta del sueño REM, que tienen alto riesgo de desarrollar enfermedad de Parkinson u otras sinucleinopatías; y 50 controles sanos. Todos los pacientes se evaluaron clínicamente por un neurólogo profesional bien capacitado y con experiencia en trastornos del movimiento. Todos los sujetos se examinaron durante una única sesión con un especialista del habla. Todos los sujetos realizaron una lectura de un texto estandarizado y fonéticamente equilibrado de 80 palabras y un monólogo sobre sus intereses,

trabajo, familia o actividades actuales durante aproximadamente 90 segundos, los atributos en el conjunto de datos son: código del participante, años, género, positivo para historial de enfermedad de Parkinson en la familia, edad en que la enfermedad de Parkinson se estableció, duración de la enfermedad desde los primeros síntomas, terapia antidepresiva, medicación antiparkinsoniana, medicación antipsicótica, equivalente de Levodopa mg/día, Clonazepam mg/día, escala Hoehn & Yahr, total UPDRS III, discurso, expresión facial, temblor en descanso – cabeza, temblor en descanso RUE, temblor en descanso – LUE, acción o temblor postural - RUE, acción o temblor postural – LUE, rigidez -cuello, rigidez – RUE, rigidez – LUE, rigidez RLE, rigidez – LLE, golpeteo del dedo – RUE, golpeteo del dedo – LUE, movimientos de la mano – RUE, movimientos de la mano -LUE, movimientos de alternación rápidos -RUE, movimientos de alternación rápidos -LUE, agilidad en la pierna -RLE, agilidad en la pierna LLE, entre otros, estos atributos se muestran en la figura 1.6.

| Participant c | Demographi  | Demographi | Clinical infor | Clinical infor | Clinical infor | Medication     | Medication   | Medication   | Medication     | Medication  |
|---------------|-------------|------------|----------------|----------------|----------------|----------------|--------------|--------------|----------------|-------------|
|               | Age (years) | Gender     | Positive hist  | Age of disea   | Duration of c  | Antidepress    | Antiparkinsc | Antipsychoti | Benzodiazep    | Levodopa ec |
| PD01          | 58          | F          | No             | 56             | 2              | No             | No           | No           | No             | 0           |
| PD02          | 68          | F          | No             | 67             | 1              | No             | No           | No           | No             | 0           |
| PD03          | 68          | M          | No             | 67             | 1              | No             | No           | No           | No             | 0           |
| PD04          | 75          | M          | No             | 73             | 2              | No             | No           | No           | No             | 0           |
| PD05          | 61          | M          | Yes            | 60             | 0.7            | No             | No           | No           | No             | 0           |
| PD06          | 58          | M          | No             | 58             | 1              | No             | No           | No           | No             | 0           |
| PD07          | 79          | M          | No             | 78             | 1              | No             | No           | No           | No             | 0           |
| PD08          | 59          | F          | No             | 57             | 2              | Yes (Aurorix)  | No           | No           | No             | 0           |
| PD09          | 73          | M          | No             | 72             | 1              | No             | No           | No           | No             | 0           |
| PD10          | 66          | M          | No             | 65             | 1              | Yes (Trittico) | No           | No           | No             | 0           |
| PD11          | 71          | M          | No             | 70             | 1              | No             | No           | No           | No             | 0           |
| PD12          | 37          | F          | No             | 32             | 5              | No             | No           | No           | No             | 0           |
| PD13          | 43          | M          | No             | 37             | 6              | No             | No           | No           | No             | 0           |
| PD14          | 70          | M          | No             | 69             | 1              | No             | No           | No           | No             | 0           |
| PD15          | 75          | F          | No             | 73             | 2.5            | No             | No           | No           | No             | 0           |
| PD16          | 64          | F          | No             | 63             | 1              | No             | No           | No           | Yes (Rivotril) | 0           |
| PD17          | 73          | F          | No             | 71             | 2              | No             | No           | No           | No             | 0           |
| PD18          | 73          | M          | No             | 72             | 1              | No             | No           | No           | No             | 0           |
| PD19          | 34          | M          | No             | 30             | 4              | No             | No           | No           | No             | 0           |
| PD20          | 70          | M          | No             | 69             | 1              | No             | No           | No           | No             | 0           |
| PD21          | 70          | M          | No             | 69             | 1              | No             | No           | No           | Yes (Rivotril) | 0           |

Figura 1.5. Conjunto de datos de biomarcadores tempranos de la EP basados en el habla natural conectada [15].

El conjunto de datos del habla de Parkinson con múltiples tipos de grabaciones de sonido [16] durante la recopilación de este conjunto de datos, se pidió a 28 pacientes con enfermedad de

Parkinson que dijeran solo las vocales sostenidas /a/ y /o/ 3 veces respectivamente, lo que hace un total de 168 grabaciones, los datos del conjunto de datos se muestran en la figura 1.8.

|                                                                                                                        |
|------------------------------------------------------------------------------------------------------------------------|
| 1,1.488,0.000090213,0.9,0.794,2.699,8.334,0.779,4.517,4.609,6.802,13.551,0.905905,0.119116,11.13,166.533,164.781,10.4  |
| 1,0.728,0.000037698,0.353,0.376,1.059,5.864,0.642,2.058,3.18,7.194,6.175,0.951285,0.066758,17.403,195.252,193.289,14.  |
| 1,1.22,0.000074041,0.732,0.67,2.196,8.719,0.875,4.347,5.166,7.548,13.04,0.911508,0.109983,12.212,158.689,164.768,12.9  |
| 1,2.502,0.000122824,1.156,1.634,3.469,13.513,1.273,5.263,8.771,16.779,15.789,0.901302,0.121982,11.384,201.997,203.471  |
| 1,3.509,0.000166927,1.715,1.539,5.145,9.112,1.04,3.102,4.927,12.823,9.307,0.856907,0.236831,10.653,211.887,208.44,11.4 |
| 1,2.47,0.000126412,1.358,1.341,4.075,10.696,1.256,5.262,7.076,9.199,15.787,0.897708,0.152955,11.987,195.952,195.222,4  |
| 1,1.583,0.000082305,0.768,0.864,2.303,9.057,1.07,3.794,5.158,7.67,11.381,0.935717,0.078695,13.705,195.535,192.316,7.5  |
| 1,1.92,0.000098625,0.926,1.031,2.777,10.184,1.108,3.65,4.611,7.127,10.951,0.898598,0.147518,12.4,196.745,194.284,5.97  |
| 1,2.257,0.000119196,1.239,1.53,3.716,8.044,0.877,3.449,4.239,7.654,10.346,0.877616,0.217236,12.831,191.345,185.423,21  |
| 1,1.594,0.00008504,0.85,0.951,2.55,7.2,0.823,2.48,3.826,9.228,7.44,0.917596,0.112336,14.039,190.838,187.775,10.087,166 |
| 1,2.286,0.000122261,1.081,1.257,3.243,8.994,0.938,3.386,5.646,11.253,10.157,0.881269,0.168753,11.084,192.349,188.506,  |
| 1,1.728,0.000092615,0.807,1.056,2.422,9.779,0.984,4.1,6.374,9.107,12.299,0.890381,0.152535,11.97,189.213,186.832,11.2  |
| 1,2.105,0.000109648,0.902,1.076,2.707,6.163,0.718,2.403,3.163,5.009,7.208,0.886134,0.188092,14.644,193.824,192.37,7.7  |
| 1,3.343,0.000164283,1.349,1.826,4.047,12.619,1.316,5.287,7.67,15.858,15.862,0.767751,0.401774,6.754,208.781,204.866,2  |
| 1,2.025,0.000099298,1.028,1.251,3.084,11.047,1.244,4.223,5.973,12.467,12.67,0.891718,0.151406,11.866,204.431,17.5      |
| 1,2.517,0.000118023,1.16,1.35,3.479,14.327,1.359,5.82,9.451,18.515,17.461,0.821869,0.283381,8.432,218.121,213.528,17.  |
| 1,3.29,0.000149035,1.567,1.822,4.702,12.714,1.363,4.259,6.697,15.432,12.778,0.853435,0.20711,9.847,218.273,220.118,31  |
| 1,5.534,0.000258089,2.38,3.171,7.14,13.54,1.512,6.187,10.903,16.528,18.56,0.715071,0.503734,5.139,206.243,215.207,17.  |
| 1,1.137,0.000053524,0.473,0.608,1.418,8.963,0.936,2.998,5.017,11.826,8.995,0.923972,0.094186,14.819,216.478,212.661,1  |
| 1,2.162,0.000099442,1.217,1.059,3.651,11.294,1.019,4.621,5.878,11.646,13.864,0.915221,0.112466,12.562,218.247,216.35   |
| 1,1.533,0.00007623,0.462,0.34,1.387,9.921,0.956,3.153,5.111,8.569,9.458,0.874335,0.200621,11.82,200.023,200.385,23.69  |
| 1,2.783,0.000135293,1.221,1.338,3.663,14.779,1.374,5.009,9.16,22.177,15.027,0.792154,0.329135,7.225,207.392,206.26,24  |
| 1,3.999,0.000187606,1.928,2.231,5.784,16.509,1.363,7.845,11.732,16.951,23.535,0.757837,0.386043,5.75,209.238,213.78,2  |

Figura 1.6. Conjunto de datos del habla de Parkinson con múltiples tipos de grabaciones de sonido [16].

En el trabajo de Sakar *et al.* [17], recolectaron, el conjunto de datos [18] debido al incremento de aplicaciones en el análisis de patrones de discurso de la enfermedad de Parkinson, está conformado por 188 pacientes con enfermedad de Parkinson (107 hombres y 81 mujeres) con edades comprendidas entre 33 y 87 años en el Departamento de Neurología de la Facultad de Medicina Cerrahpasa de la Universidad de Estambul. El grupo control está formado por 64 individuos sanos (23 hombres y 41 mujeres) con edades que varían entre 41 y 82 años. Durante el proceso de recolección de datos, el micrófono se configuró a 44,1 KHz y luego del examen médico, se recopiló la fonación sostenida de la vocal /a/ de cada sujeto con 3 repeticiones, los datos se muestran en la figura 1.9.

| id | gender | Baseline Features |         | RPDE    | numPulses | numPeriods | meanPeriod | stdDevPeriod | locPctJitter | locAbsJitter | rapJitter | ppq5Jitter | ddpJitter | locShimmer |
|----|--------|-------------------|---------|---------|-----------|------------|------------|--------------|--------------|--------------|-----------|------------|-----------|------------|
|    |        | PPE               | DFA     |         |           |            |            |              |              |              |           |            |           |            |
| 0  | 1      | 0.85247           | 0.71826 | 0.57227 | 240       | 239        | 0.00806353 | 8.68E-05     | 0.00218      | 1.76E-05     | 0.00067   | 0.00129    | 0.002     | 0.05883    |
| 0  | 1      | 0.76686           | 0.69481 | 0.53966 | 234       | 233        | 0.00825826 | 7.31E-05     | 0.00195      | 1.61E-05     | 0.00052   | 0.00112    | 0.00157   | 0.05516    |
| 0  | 1      | 0.85083           | 0.67604 | 0.58982 | 232       | 231        | 0.00833959 | 6.04E-05     | 0.00176      | 1.47E-05     | 0.00057   | 0.00111    | 0.00171   | 0.09902    |
| 1  | 0      | 0.41121           | 0.79672 | 0.59257 | 178       | 177        | 0.01085773 | 0.00018274   | 0.00419      | 4.55E-05     | 0.00149   | 0.00268    | 0.00446   | 0.05451    |
| 1  | 0      | 0.3279            | 0.79782 | 0.53028 | 236       | 235        | 0.00816157 | 0.00266886   | 0.00535      | 4.37E-05     | 0.00166   | 0.00227    | 0.00499   | 0.0561     |
| 1  | 0      | 0.5078            | 0.78744 | 0.65451 | 226       | 221        | 0.0076312  | 0.00269638   | 0.00783      | 5.97E-05     | 0.00232   | 0.00312    | 0.00697   | 0.07752    |
| 2  | 1      | 0.76095           | 0.62145 | 0.54543 | 322       | 321        | 0.00599099 | 0.00010727   | 0.00222      | 1.33E-05     | 0.00036   | 0.00094    | 0.00108   | 0.03203    |
| 2  | 1      | 0.83671           | 0.62079 | 0.51179 | 318       | 317        | 0.00607386 | 0.00013574   | 0.00282      | 1.71E-05     | 0.00034   | 0.00088    | 0.00103   | 0.063      |
| 2  | 1      | 0.80826           | 0.61766 | 0.50447 | 318       | 317        | 0.00605719 | 6.93E-05     | 0.00161      | 9.73E-06     | 0.00027   | 0.00068    | 0.00081   | 0.02783    |
| 3  | 0      | 0.85302           | 0.62247 | 0.54855 | 493       | 492        | 0.00391022 | 3.99E-05     | 0.00075      | 2.93E-06     | 9.00E-05  | 0.00025    | 0.00027   | 0.0567     |
| 3  | 0      | 0.80657           | 0.67256 | 0.61745 | 488       | 487        | 0.00395611 | 5.38E-05     | 0.00083      | 3.29E-06     | 0.0001    | 0.00026    | 0.00029   | 0.06639    |
| 3  | 0      | 0.82653           | 0.58326 | 0.44555 | 498       | 497        | 0.00387269 | 3.26E-05     | 0.00069      | 2.68E-06     | 7.00E-05  | 0.00021    | 0.00022   | 0.02531    |
| 4  | 0      | 0.8726            | 0.78996 | 0.78026 | 492       | 491        | 0.00392415 | 6.72E-05     | 0.0028       | 1.10E-05     | 0.00077   | 0.00184    | 0.0023    | 0.20811    |
| 4  | 0      | 0.81148           | 0.76831 | 0.70809 | 305       | 304        | 0.00631642 | 0.00324532   | 0.00341      | 2.16E-05     | 0.00093   | 0.00141    | 0.0028    | 0.13878    |
| 4  | 0      | 0.80978           | 0.77992 | 0.6918  | 291       | 290        | 0.00662419 | 0.00275658   | 0.00457      | 3.03E-05     | 0.00159   | 0.00292    | 0.00477   | 0.13069    |
| 5  | 1      | 0.81471           | 0.61483 | 0.33216 | 300       | 299        | 0.00643329 | 3.88E-05     | 0.00085      | 5.45E-06     | 0.00017   | 0.00042    | 0.00051   | 0.04046    |
| 5  | 1      | 0.83269           | 0.62018 | 0.37051 | 286       | 285        | 0.00675426 | 5.17E-05     | 0.00111      | 7.52E-06     | 0.00024   | 0.00059    | 0.00072   | 0.02995    |
| 5  | 1      | 0.82016           | 0.63124 | 0.37031 | 266       | 265        | 0.00725672 | 4.86E-05     | 0.00086      | 6.28E-06     | 0.0002    | 0.00045    | 0.00059   | 0.02734    |
| 6  | 1      | 0.78067           | 0.66085 | 0.44583 | 283       | 282        | 0.00682409 | 0.00013825   | 0.00177      | 1.21E-05     | 0.00025   | 0.00061    | 0.00075   | 0.0481     |
| 6  | 1      | 0.79774           | 0.71199 | 0.36714 | 289       | 288        | 0.00669304 | 6.49E-05     | 0.00122      | 8.19E-06     | 0.0002    | 0.00049    | 0.00061   | 0.08552    |
| 6  | 1      | 0.82169           | 0.62901 | 0.36176 | 292       | 291        | 0.00662361 | 2.80E-05     | 0.00084      | 5.58E-06     | 0.00018   | 0.00041    | 0.00055   | 0.02324    |

Figura 1.7. Conjunto de datos de clasificación de la EP [18].

## 1.2 Situación tecnológica, económica y operativa de la empresa

El Instituto Tecnológico de Orizaba es una institución pública que depende de la Secretaría de Educación Pública SEP y pertenece al Tecnológico Nacional de México. Se encuentra ubicado en Oriente 9, Colonia Emiliano Zapata, en la ciudad de Orizaba, Veracruz. Esta institución ofrece carreras de licenciatura, maestría y doctorado. En el área de maestrías ofrece las carreras de Maestría en Ingeniería Electrónica, Maestría en Ingeniería Industrial, Maestría en Ciencias en Ingeniería Química, Maestría en Ingeniería Administrativa y la Maestría en Sistemas Computacionales. Asimismo, ofrece un Doctorado en Ciencias de la Ingeniería.

## 1.3 Planteamiento del problema

El aumento de la longevidad en la civilización contemporánea lleva consigo un incremento preocupante en la incidencia de enfermedades neurodegenerativas, como el Parkinson, y esto se atribuye en parte a diversos factores, tales como factores ambientales y genéticos, entre otros, estadísticas como las de la Organización Mundial de la Salud informan que las enfermedades neurodegenerativas como el Parkinson, están en constante aumento, las estimaciones mundiales indican que en el 2019 más de 8,5 millones de personas eran afectadas por la enfermedad de Parkinson, lo que provocó el fallecimiento de 329 000 de personas en el año 2020, [19]., Martínez *et al.* [20] señalan que, en México, la enfermedad de Parkinson aumentó la incidencia de 6.7 en 2014 a 14.9 por 100 000 habitantes en 2023, cifras como estas destacan la urgente necesidad de estrategias más efectivas para su diagnóstico temprano, la enfermedad de

Parkinson no solo representan una carga significativa para las personas afectadas y sus familias, sino que también ejercen una presión económica considerable sobre los sistemas de atención médica y los gobiernos. Actualmente existen técnicas para la detección de la Parkinson como la tecnología PET/ MRI utilizada por Leung *et al.*[21], la cual es una tecnología híbrida que combina imágenes morfológicas de tejidos blandos obtenidas por MRI (*Magnetic Resonance Imaging*, Imagen por Resonancia Magnética) e imágenes funcionales obtenidas a través de tomografías por emisión de positrones PET(*Positron Emission Tomography*, Tomografía por Emisión de Positrones) que debido a los radiofármacos usados es una técnica invasiva para el paciente, también técnicas como el diagnóstico basado en biopsias gástricas como mencionan Horstink *et al.* [22], que ofrece una alta precisión para la confirmación del diagnóstico pero al ser un método quirúrgico tiene riesgos asociados con la extracción de tejido, y los costos asociados con este tipo de diagnósticos resultan ser poco accesibles, por lo que se requiere desarrollar nuevos enfoques que no sean invasivos y que además usen técnicas de IA que permitan realizar un pronóstico bastante aceptable para abordar este desafío creciente, es fundamental identificar los síntomas de manera anticipada para facilitar un tratamiento adecuado y contrarrestar los efectos perjudiciales de estas enfermedades.

En este sentido, se propone la implementación de un software de detección temprana de Parkinson, con el propósito de eliminar la subjetividad inherente a la evaluación realizada por profesionales de la salud y, al mismo tiempo, incrementar la cantidad de pacientes diagnosticados. Este enfoque no solo tiene el potencial de mejorar significativamente la calidad de vida de los afectados, sino que también contribuye sustancialmente a la reducción de costos asociados con el tratamiento de estas enfermedades en el ámbito de la salud pública.

## **1.4 Objetivo general y objetivos específicos**

En esta sección se plantea el objetivo general y los objetivos específicos de la tesis.

### **1.4.1 Objetivo general**

Desarrollar un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de procesamiento de lenguaje natural.

#### **1.4.2 Objetivos específicos**

- Analizar los algoritmos y técnicas de PLN para la extracción de elementos vocales para la detección de la temprana de la enfermedad de Parkinson.
- Diseñar una arquitectura de software y un conjunto de prestaciones de servicio para el desarrollo del módulo de software para la identificación temprana de la enfermedad de Parkinson.
- Desarrollar un módulo de software para la identificación temprana de la enfermedad de Parkinson mediante técnicas de procesamiento de lenguaje natural.
- Evaluar y validar el módulo de software a través de un conjunto de casos de estudio como prueba de concepto.

#### **1.5 Justificación**

La amplia incidencia de la enfermedad de Parkinson, es un problema de salud a nivel mundial en el cual las personas que padecen esta enfermedad tienden a sufrir un daño neurodegenerativo con el paso del tiempo, presentando, entre algunos síntomas, dificultades para andar, temblores y alteraciones en la coordinación de movimientos, así como también síntomas no motores, destacando principalmente, problemas del sueño, depresión, los trastornos de control de impulsos y problemas cognitivos.

Por otro lado, el constante avance tecnológico y su aceptación a nivel mundial de integrar soluciones de Tecnologías de la Información (TI) en el sector médico, es un factor que representa mayor relevancia día con día, esto resulta porque su uso e implementación permite diagnosticar y tratar a los pacientes de una manera rápida y eficiente optimizando el uso de recursos en el sistema de salud.

El presente trabajo provee un impacto relevante para el caso de estudio al no ser un método invasivo y aplicar el enfoque de analizar y determinar puntos clave en la detección temprana de la enfermedad de Parkinson mediante características relacionadas con la voz del paciente, destacando el objetivo principal a evaluar que menciona, desarrollar un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de procesamiento del lenguaje natural, se obtendrán los siguientes beneficios:

- **Detección temprana:** Permite identificar signos tempranos de la enfermedad de Parkinson antes que los síntomas motores sean evidentes, lo que lleva a un tratamiento más temprano y efectivo.
- **No invasivo:** La detección por voz no requiere procedimientos invasivos ni pruebas médicas costosas, lo que la hace más accesible y menos intimidante para los pacientes.
- **Reducción de costos:** Al evitar pruebas médicas más costosas y complicadas, la detección por voz ayuda a reducir costos asociados con el diagnóstico y el tratamiento de la enfermedad de Parkinson.
- **Facilita el diagnóstico:** Los profesionales médicos al utilizar el software como una herramienta complementaria para respaldar el diagnóstico clínico, mejoran la precisión del diagnóstico.
- **Mejora la calidad de vida:** Un diagnóstico temprano y un tratamiento adecuado ayudan a los pacientes a mantener una mejor calidad de vida y retrasan la progresión de la enfermedad.
- **Mayor accesibilidad:** Al utilizarse en entornos remotos o en áreas donde no hay acceso inmediato a especialistas en Parkinson, se amplía el acceso al diagnóstico y al tratamiento.

- **Conciencia y educación:** El uso del software para la detección temprana de Parkinson por voz aumenta la conciencia sobre la enfermedad y fomenta la educación sobre los síntomas y la importancia del diagnóstico temprano.

## Capítulo 2. Estado de la práctica

En este capítulo se proporciona un análisis de los estudios relacionados con el desarrollo de software para el análisis de enfermedades neurodegenerativas. Se abordan investigaciones que utilizaron técnicas de inteligencia artificial para el diagnóstico de la enfermedad de Parkinson.

### 2.1 Trabajos relacionados

En el estudio realizado por León-Cabrera *et al.* [23], se llevó a cabo una evaluación de los mecanismos de predicción lingüística mediante ERP (*Event-related potential*, Potenciales Relacionados con Eventos) con el objetivo de abordar la interrogante sobre la preservación de la predicción lingüística en la enfermedad de Parkinson, a pesar de la escasez de conocimiento en este ámbito. Para llevar a cabo esta evaluación, se procedió a seleccionar una muestra de pacientes con desórdenes de movimiento, a los participantes se les informó que el estudio comprendería de pruebas de comprensión neuropsicológica y la realización de grabaciones de EEG (*Electroencephalography*, Electroencefalograma) durante dos sesiones. Los resultados del experimento al comparar el subconjunto de pacientes con enfermedad de Parkinson con cognición normal contra el grupo de pacientes con enfermedad de Parkinson y con deterioro cognitivo leve, revelaron que la capacidad de procesamiento predictivo del lenguaje se mantiene en los pacientes con enfermedad de Parkinson con cognición normal con un puntaje en la predicción lingüística de 17.63, a diferencia de aquellos con enfermedad de Parkinson y con deterioro cognitivo leve que obtuvieron un puntaje de 10.52 en la predicción lingüística, lo que representa limitaciones cognitivas que obstaculizan los mecanismos asociados con la predicción semántica. Estas limitaciones afectaron negativamente el procesamiento de oraciones debido a una semántica más pobre y a un procesamiento semántico menos eficiente cuando los contextos son predictivos, además, tanto la disfunción ejecutiva como el daño dentro de las redes semánticas subyacen a estas dificultades, tal como lo sugiere su asociación con puntajes bajos de fluidez verbal.

Debido a la falta de herramientas para la evaluación de las deficiencias del habla en pacientes con enfermedad de Parkinson, Orozco-Arroyave *et al.* [24] desarrolló un software denominado *NeuroSpeech*, el cual facilita el análisis de señales patológicas del habla, uno de los enfoques

fundamentales de este programa es la realización de un análisis basado en un Regresor de Vector de Soporte. En el análisis fonatorio realizado a un paciente con enfermedad de Parkinson, se tomó en cuenta medidas de perturbación donde la fluctuación obtuvo 0.58Hz, el brillo 3.42% y el cociente de perturbación de amplitud 3.71%, y cociente de perturbación de tono de 0.10%, dichas medidas permiten observar alteraciones en la vibración de las cuerdas vocales en el paciente con enfermedad de Parkinson, lo que conlleva a una amplitud o volumen de voz inestable durante la producción de una vocal sostenida, característica típica de la disartria asociada a la enfermedad de Parkinson. El análisis de la articulación mostró una reducción en las capacidades articulatorias. En el análisis prosódico, se observó que el paciente presentó valores más altos de desviación estándar en la duración de los silencios y los segmentos sonoros. Además, se confirmó la mono tonicidad del habla disártrica, a través de la menor desviación estándar de la frecuencia fundamental en comparación con la referencia. Por último, el análisis de inteligibilidad obtuvo un 83% de exactitud de pronunciación y 50% de similitud al ser reproducidas 2 series de palabras.

Por una falta de evidencia en la correlación neuronal del procesamiento sintáctico en pacientes con enfermedad de Parkinson en el trabajo de Hyder *et al.* [25], se mostró mediante un conjunto de técnicas de Regresión Logística, que pacientes recién diagnosticados con enfermedad de Parkinson difieren de controles sanos en la conectividad funcional, dentro de las redes corticales activas, durante el procesamiento automático del lenguaje hablado. El experimento analizó los resultados de la prueba aplicada a 13 pacientes con enfermedad de Parkinson recién diagnosticados y un grupo control sano, a todos los participantes se les mostró una película muda y se les pidió se concentraran en la película mientras se grababan los resultados de la MEG (*Magnetoencephalography*, Magneto encefalografía), mientras tanto se reprodujeron 2 secuencias de palabras, la secuencia inicial (condición léxica semántica), se integró por verbos de acción, para la segunda secuencia de palabras (condición morfosintáctica); se presentaron enunciados con forma incorrecta. Para la clasificación de los verbos de acción se obtuvo una precisión de 0.781 del cual 73% de datos de los pacientes control y 82% de datos de pacientes con enfermedad de Parkinson se predijeron correctamente, también la clasificación usando verbos abstractos obtuvo una precisión de 0.688, de los cuales 60% de los datos de los controles

y 76% de los datos de pacientes con enfermedad de Parkinson se clasificaron correctamente, finalmente la clasificación de formas morfosintácticas incorrectas obtuvo un 0.648, 62% de los datos de los controles y 68% de los datos de pacientes con enfermedad de Parkinson se clasificaron correctamente.

En el trabajo de Mosfata *et al.* [26] surgió la necesidad de determinar cuál método tiene un mejor desempeño para evaluar si un paciente tiene enfermedad de Parkinson para ello se evaluó el desempeño de 3 métodos para diagnosticar enfermedad de Parkinson: Árboles de Decisión, Bayesiano Ingenuo y Redes Neuronales. Para la evaluación se utilizó un conjunto de datos de la Universidad de California-Irvine de su repositorio de aprendizaje automático, en el experimento con Árboles de decisión, se obtuvo que la mayor precisión se encontró dividiendo en 30% de entrenamiento y 70% de prueba, el mayor puntaje de precisión obtuvo 91.63% cuando el RMSE (*Root Mean Square Error*, Error Cuadrático de la Raíz) es el más bajo 0.2701. En el experimento de Bayesiano Ingenuo, se usó una función de activación para las salidas de Bayesiano Ingenuo donde se obtuvo un resultado de 89.46% cuando el RMSE es el más bajo, 0.2668. En el experimento con Redes Neuronales los resultados mostraron que la precisión más alta se encontró dividiendo los datos en 40% para el entrenamiento y 60% para prueba, con la precisión más alta de 91.01% de puntaje cuando el RMSE es el más bajo de 0.2871. Estos resultados mostraron que el método con mayor precisión es el de Árboles de decisión seguido de las Redes Neuronales y Bayesiano Ingenuo.

Debido a una falta de conocimiento sobre los efectos de la terapia con Levodopa en el comportamiento y gesticulación en el acompañamiento del discurso de pacientes con enfermedad de Parkinson en el análisis de Duncan. [27] se llevó a cabo un experimento para obtener y analizar datos sobre los efectos que tiene el medicamento Levodopa y la terapia de LSVT (*Lee Silverman Voice Treatment*, Tratamiento de Voz Lee Silverman) en pacientes con enfermedad de Parkinson y los gestos que utilizan para expresar la narración de un video y así determinar en qué variables concentrarse en un conjunto mayor de muestras para ser recolectadas subsecuentemente. Para los datos del discurso narrativo de cada participante, se obtuvieron usando una caricatura que provocó los estímulos, mientras eran grabados con

videocámaras. El análisis se realizó de 8 videgrabaciones de narraciones, se tomaron en cuenta las pausas, pausas de respiración, auto interrupciones, autocorrecciones, repeticiones, reinicios, disfluencias y malas pronunciaciones. Como resultado se observó que el paciente en terapia de LSVT tuvo un decremento del 34% en los gestos utilizados en su narración, el paciente B4 tuvo un decremento del 54% en el uso de gestos en su narración después de tomar el medicamento y el paciente B5 un decremento del %14 después de tomar el medicamento, estos resultados llevan a la conclusión de que el aumento de gestos parece estar asociados con el incremento de la disfluencia en el discurso.

Por la falta de métodos supervisados ideales para la prognosis cuando no hay etiquetas Jiang *et al.* [28] modelaron los patrones fisiológicos de una persona sana, utilizando aprendizaje automático para identificar sujetos anómalos que tuvieran alto riesgo de enfermedad de Parkinson para más adelante pedir asistencia médica, se incorporaron métodos de Auto Aprendizaje Supervisado para aprender buenas representaciones de datos sin la necesidad de etiquetas expertas. Para el experimento se utilizaron los datos del estudio mPower, mPower es un estudio a gran escala que concentra los datos de sujetos usando su teléfono inteligente, mientras caminaban en línea recta, a la vez los sensores capturan la cinemática (movimiento, trayectoria y tiempo) de los sujetos. El experimento dio como resultado, que el modelo con el objetivo *One-Class Deep SVDD* obtuvo la mayor puntuación de AUC (*Area Under Curve*, Área debajo de la curva) tomando en cuenta el número de *frames* a predecir de 9 con el AUC de 67.3, obteniendo una mejor representación de enfermedad de Parkinson y sujetos sanos separados. De esta manera los autores demostraron que este acercamiento extrae funciones que discriminan mejor después del preentrenamiento sobre muestras de datos de solamente sujetos sanos.

En la revisión de Locke *et al.* [29] se identificó la falta de información sobre el Procesamiento de Lenguaje Natural y su uso en EHRs (*Electronic Healt Records*, Registros de salud Electrónicos) a causa de esto se realizó una revisión sobre el Procesamiento de Lenguaje Natural donde se da a conocer información sobre su estado actual en relación con los EHRs y el cómo se aplicó Procesamiento de Lenguaje Natural en un modelo que permite diagnósticos

tomando como datos los EHRs. Para la investigación se usó un preproceso de los datos para la realización de tareas, tales como *tokenizacion*, lematización, y desambiguación del sentido de la palabra, para realizar el mapeo de tareas que permiten a las palabras tener múltiples significados que cambian sobre el tiempo dependiendo de su popularidad y contexto, para el entrenamiento de los modelos se usó el conjunto de datos con una proporción de 80:20 entre validación y entrenamiento. La revisión menciona como la transferencia de conocimiento es la aplicación de conocimiento aprendido de un problema existente a un nuevo problema, en la forma de un modelo existente que es el punto de iniciación para la creación de otro modelo, su uso es útil cuando se requieren largos conjuntos de datos, y forma parte del aprendizaje automático como modelo para la detección de anomalías en imágenes médicas y también en Procesamiento de Lenguaje Natural. Como resultado se obtuvo una revisión del estado actual del Procesamiento de Lenguaje Natural aplicado en el contexto médico.

Por la falta de conocimiento acerca de los cambios en la comunicación por enfermedad de Parkinson en la investigación de Miller *et al.* [30] se realizó una revisión sobre los cambios que tiene la comunicación con la enfermedad de Parkinson, el trabajo menciona que la mayoría de las personas con enfermedad de Parkinson notan cambios en su comunicación, la voz se altera y en etapas avanzadas la articulación presenta inteligibilidad, así como disprosodia, defecto cognitivo lingüístico, estos cambios impactan en el humor y la participación social de los pacientes. También se menciona que los pacientes con enfermedad de Parkinson tienden a tener una voz más silenciosa (hipofonía), articulación imprecisa (disartria hipocinética) y la proporción de sus discursos alterada, ocasionando que sus dificultades no solo sean la salida del habla, si no también aspectos de procesamiento y entendimiento, ya que la comunicación es central en lograr y mantener una vida psicosocial. Otro aspecto afectado por enfermedad de Parkinson es la habilidad de saber cuándo introducir material o ser más explícito en su discurso, así como alteraciones faciales, postura del cuerpo, por último, se mencionó que las terapias del comportamiento son la mejor opción para rehabilitación de los cambios de comunicación. Como resultado de esta revisión se determinó que la estimulación profunda del cerebro actualmente resulta en efectos perjudiciales y encuentra las terapias de comportamiento como la mejor opción de tratamiento.

En la investigación de Novotný *et al.* [31] se mencionó que existe una falta de clasificadores de enfermedad de Parkinson que tomen en cuenta las funciones de la articulación como la calidad de voz, coordinación de la actividad de la laringe, la precisión de la articulación de una consonante, movimiento de la lengua, despertar de la oclusión y cronometraje del discurso, por este motivo se desarrolló un algoritmo de segmentación automático que permite la detección del estallido inicial, inicio de vocales, y la oclusión, así como también varias funciones acústicas que se desarrollan por la disartria, y un experimento para diferenciar sujetos con enfermedad de Parkinson de sujetos control. La clasificación del experimento se basó en el clasificador de Máquinas de Vector Soporte usando todas las locuciones para obtener estimaciones de clasificación robustas, siendo el objetivo del experimento separar 2 clases, enfermedad de Parkinson y participantes control, basado en la extracción automática de funciones de articulación que se preseleccionaron usando correlación de Pearson y correlación de distancia. Los resultados señalan que el rendimiento del algoritmo para todas las sílabas obtuvo un 79.2% para el estallido inicial, 81.7% para el inicio de la vocal y 77.3% para la oclusión, la exactitud de la clasificación de enfermedad de Parkinson y pacientes control obtuvo el 88%, cabe a destacar que la clasificación con exactitud más elevada por una función articulatoria se obtuvo por la articulación de consonantes lo que sugiere que es un poderoso indicador de enfermedad de Parkinson.

En el trabajo de Mollaei *et al.* [32] se buscó confirmar la hipótesis propuesta sobre, el papel que ocupa el tronco encefálico en los déficits del discurso en pacientes con enfermedad de Parkinson, para ello se realizó una investigación evaluando la implicación del tronco encefálico en el procesamiento de sonidos complejos del discurso en relación con los déficits motores del habla en enfermedad de Parkinson, se tomó en cuenta un componente de la respuesta auditoria del tronco encefálico que refleja propiedades acústicas como el tono y la frecuencia de los formantes, también conocida como FFR (*Frequency-Following Response*, Respuesta de Seguimiento de Frecuencia), que refleja una representación de los armónicos y variantes de tiempo correspondientes al tono y la frecuencia del primer formante de la vocal. Para el experimento se reclutaron 15 pacientes con enfermedad de Parkinson y 15 participantes

control. Para la evaluación de disartria se le pidió a cada participante leyera el pasaje del arcoíris, que es una evaluación por medio de un pasaje estándar. Los resultados mostraron que los individuos con enfermedad de Parkinson mostraron una mayor amplitud FFR en respuesta a la frecuencia asociada con el inicio de formante 0 de la sílaba /da/ comparada con el grupo control, esto indica una codificación mejorada del tono vocal, evidenciada por el aumento de la amplitud de FFR en el rango de frecuencia de 80-120 Hz, en individuos con enfermedad de Parkinson en comparación con los participantes control.

Por la falta de conocimiento sobre los modelos que evalúan los síntomas de la enfermedad de Parkinson Lonini *et al.* [33] evaluaron el valor relativo de varios métodos para incrementar la cantidad de datos de entrenamiento cuando se desarrollan modelos de aprendizaje automático para la detección de síntomas de enfermedad de Parkinson durante actividades representativas de tareas diarias, se grabaron datos de movimiento de 6 sensores usables en las manos, brazos y muslos que se entrenaron en un clasificador de aprendizaje automático para detectar la presencia de temblores o bradicinesia en las extremidades superiores, mientras los individuos con enfermedad de Parkinson realizaban una serie actividades diarias y tareas estandarizadas usadas en evaluaciones en clínicas. Se entrenaron conjuntos estadísticos mediante Bosques Aleatorios y clasificadores de Redes Neuronales Convolucionales usando datos de un sensor o de múltiples sensores, y evaluando la contribución de tener sensores en ambas partes del cuerpo, también se evaluó el efecto de tener cierto número de participantes para el entrenamiento de los modelos en el rendimiento del modelo. Los modelos de Bosques Aleatorios entrenados en los datos disponibles produjeron el mayor AUROC para la detección de bradicinesia de 0,73 con el 95% de precisión y temblor de 0,79 con el 95% de precisión en todas las actividades, el experimento para evaluar el rendimiento de acuerdo con la cantidad de participantes mostró que 10 individuos son la mejor opción para el entrenamiento de los modelos ya pasando de este número no se mejoraba la predicción.

En la publicación de Murray *et al.* [34] detectaron una falta de conocimiento sobre las funciones lingüísticas de transcripciones textuales de pacientes con enfermedad de Parkinson por ello se realizaron 2 experimentos, para el primer experimento se les pidió a los participantes

describieran una acción que realizan diariamente, como ejemplo se les dio los pasos a seguir para lavar platos, una vez entendidas las instrucciones el experimento empezó, para el segundo experimento se les pidió a los participantes que dieran direcciones precisas para llegar de su casa a un lugar familiar para ellos, por ejemplo el zoológico. Se usó principalmente Bosques Aleatorios, modelos de clasificación y se emplearon procedimientos de validación cruzada, el resultado de la prueba del modelo de clasificación binaria: jóvenes contra sujetos mayores tuvo un puntaje de predicción con exactitud de 0.927 y un AUC de 0.913 usando el modelo de regresión Bosques Aleatorios. Para el último conjunto de experimentos se predijo las habilidades cognitivas de todos los sujetos en todas las cohortes, se tomaron en cuenta los puntajes de prueba de usos alternativos; donde el mejor modelo para su predicción fue el modelo referencia con un puntaje de 82.54, para el inventario de depresión Beck; el mejor modelo para su predicción fue el modelo ensamblador con un puntaje de 6.69, y para las pruebas de habilidades fonológicas; el mejor modelo para su predicción fue el modelo de Lasso con un puntaje de 75.92, de esta manera se usó el Procesamiento de Lenguaje Natural y aprendizaje automático para detectar evidencia de enfermedad de Parkinson en la transcripción de tareas generadas por sujetos.

En la publicación de Chrnowski *et al.* [35] se menciona que no existe una prueba antemortem para el diagnóstico de enfermedad de Parkinson por ello se propuso una arquitectura basada en wav2vec 2.0 para probarla en una configuración de transferencia de aprendizaje para diagnosticar enfermedad de Parkinson, para los experimentos se utilizó partes entrenadas del modelo wav2vec 2.0, wav2vec 2.0 es un modelo trasformador de reconocimiento de voz de audio sin procesar, el modelo es pre entrenado en una manera no supervisada y se aplicó el mecanismo de activación GRU (*Gated recurrent units*, Unidades Recurrentes Cerradas), para el conjunto de datos se reunieron 38 pacientes de enfermedad de Parkinson en diferentes etapas del desarrollo de la enfermedad. El modelo con la mejor predicción fue el de convoluciones congeladas que obtuvo un 97.92% de precisión y un 0.99 de AUC, seguido del modelo con pre entrenamiento convolucional y afinación completa que obtuvo un 83.33% de precisión y un 0.84 de AUC, y finalmente el modelo sin pre entrenamiento convolucional y entrenamiento completo obtuvo un 83.33% de precisión y un 0.80 de AUC, de los que se observó que el pre

entrenamiento mejora el rendimiento de la clasificación y el afinamiento preciso de partes convolucionales degrada el rendimiento de la clasificación.

En el trabajo de Pappagari *et al.* [36] mencionan que a causa de la falta de evaluaciones del discurso para detectar la enfermedad de Alzheimer, su investigación tuvo como objetivo analizar el uso de 2 técnicas de Redes Neuronales Profundas, x-vectors y BERT, en la detección de enfermedad de Alzheimer y MMSE (*Mini-Mental Status Examination*, Mini-Examen del Estado Mental), para llevar a cabo los experimentos se ocupó el conjunto de datos del desafío enfermedad de Alzheimer ReSS que contiene 2 subconjuntos con discursos y transcripciones de hablantes con enfermedad de Alzheimer y sanos. Para modelar las características de articulación, prosodia y fonatoria de los hablantes en el conjunto de datos, se implementó una representación obtenida con un modelo x-vector entrenado para el reconocimiento de los hablantes, que se usa para caracterizar enfermedades neurológicas como enfermedad de Parkinson, para complementar la caracterización del x-vector se adicionó el entrenamiento de los silencios. Para modelar las manifestaciones lingüísticas-fonológicas de enfermedad de Alzheimer en el discurso se implementó el modelo BERT. Para la detección de enfermedad de Alzheimer, se obtuvieron los puntajes de los modelos acústicos y basados en transcripción para todas las locuciones de pliegues de prueba durante la etapa de validación cruzada, después se emplearon las predicciones en un esquema de validación cruzada para entrenar y probar la función de puntajes usando el modelo GBR (*Gradient boost regresor*, Regresor de Aumento Gradiente). Los mejores resultados fueron obtenidos por el conjunto de modelos acústico adicionando el modelo de silencios y el de transcripción obteniendo una exactitud del 81.48% para la detección de enfermedad de Alzheimer y predicción de MMSE.

En el aporte de Nogales *et al.* [37] se identificó la falta de evaluaciones para determinar enfermedad de Parkinson usando EEGs (*Electroencephalograms*, Electroencefalogramas) por lo cual, se desarrolló un método no invasivo para diagnosticar enfermedad de Parkinson mediante el modelo BERT (*Bidirectional Encoder Representations from Transformer*, Representaciones de Codificador Bidireccional desde Transformador), que pertenece al Procesamiento de Lenguaje Natural. Se compararon los EEGs de pacientes con enfermedad de

Parkinson realizando tareas de evaluación, contra los EEGs de sujetos control, basándose en textos y EEGs procesados como secuencias de datos. Se reclutaron 80 pacientes del Hospital Beata María Ana en Madrid, todos los pacientes se diagnosticaron de acuerdo a la escala Hoehn y Yahr, y 24 pacientes saludables como control, cada sujeto estaba cómodamente sentado con sus manos en su regazo, con la mandíbula relajada y sus ojos abiertos, mirando a una pared blanca, después de esto cada paciente tuvo que golpear su pulgar con el dedo índice de la mano izquierda continuamente por 5 intervalos de 30 segundos, finalmente, se repitió la tarea con la mano derecha. El módulo de clasificación es un perceptrón multicapas con una capa de entrada de 64 neuronas, una capa oculta de 268 neuronas seguida de una salida SoftMax encima de 2 clases representando las etiquetas de enfermedad de Parkinson, y pacientes sanos. Como resultado se obtuvo una exactitud del 93.45% al diagnosticar la enfermedad de Parkinson.

En la investigación de Chakraborty *et al.* [38] se mencionó que existe una falta de automatización en la prueba para la detección de enfermedad de Parkinson a través de dibujos de espirales y ondas por lo que se desarrolló un sistema para analizar y diferenciar los patrones de dibujos de espirales y ondas realizados por pacientes sanos y con enfermedad de Parkinson, los datos del estudio se recolectaron de un repositorio llamado Kaggle's y para la adquisición de datos, 55 sujetos se reclutaron, de los cuales 28 sujetos pertenecen al grupo control y 27 al grupo con enfermedad de Parkinson, todos los sujetos realizaron 2 pruebas llamadas, la prueba de dibujo de Espiral y la prueba de dibujo de Onda. Para el desarrollo del sistema se usaron 2 dimensiones de C-Redes Neuronales y clasificadores de conjuntos de votación para analizar los patrones de dibujo y detección de enfermedad de Parkinson. Se utilizaron, un total de 102 dibujos de espirales y 102 dibujos de ondas para entrenar y validar el sistema. Para el desarrollo del clasificador 2 algoritmos diferentes se usaron: Regresión Logística y Bosques Aleatorios, ambos clasificadores toman las probabilidades de predicción de C-Redes Neuronales onda y espiral y predicen la salida de si es un paciente sano o con enfermedad de Parkinson. Al final, las predicciones de ambos clasificadores se toman por voto promedio y el resultado final es presentado, el modelo desarrollado impulsó una precisión del 93.3%, una recuperación promedio del 94%, una precisión promedio del 93.5% y una calificación f1 promedio de 93.94%.

En el trabajo de Frid *et al.* [39] menciona que al momento de realizar el trabajo no existían sistemas que no requirieran intervención humana para el análisis de datos, procesamiento y clasificación de resultados para el diagnóstico de enfermedad de Parkinson por lo cual se desarrolló un sistema donde se mostró que la información para diagnosticar enfermedad de Parkinson es extraída directamente de las señales de voz sin la intervención humana o análisis de los datos, el sistema también logró distinguir grados de severidad de enfermedad de Parkinson. Las funciones escogidas son señales de audio estándar, se usan típicamente en tareas de análisis del discurso, como discurso a texto y reconocimiento del hablante. El sistema consiste en los algoritmos de adquisición de datos; donde los pacientes los analizó un médico, y los evaluó por medio de UPDRS, después se les pidió que leyeran el pasaje del arcoíris de manera natural para grabarlos. El sistema se compuso de las siguientes etapas: preprocesamiento, extracción de funciones, clasificación; para la etapa de clasificación, se usó Máquinas de Vector Soporte, C-Clasificador de Vectores de Soporte y una función de kernel radial básico para realizar una segunda clasificación de datos. Para el sistema de evaluación un total de 43 pacientes con enfermedad de Parkinson y 9 controles se grabaron leyendo el pasaje del arcoíris, obteniendo un promedio de precisión general de resultados del 81.8%.

En el estudio de Nissar *et al.* [40] se menciona que no se cuenta con un diagnóstico de enfermedad de Parkinson a través de un modelo con XGBoost por lo que se realizó un experimento para determinar el rendimiento del modelo de aprendizaje automático XGBoost en el diagnóstico de enfermedad de Parkinson comparado con los modelos, Bayesiano Ingenuo, Vecinos Más Cercanos, Bosques Aleatorios, Arboles de decisión, Máquinas de Vector Soporte y Perceptrón Multicapa. La metodología comenzó con la colección de datos para el análisis de voz extraído de un repositorio de aprendizaje automático que contiene datos de voz de pacientes de enfermedad de Parkinson y sujetos sanos denominado UCI, que consiste en 756 instancias y 754 atributos, pertenecientes a 188 pacientes de enfermedad de Parkinson, y 64 individuos control, realizando 3 repeticiones de fonación sostenida. El preprocesamiento de los datos es una combinación de 2 procesos individuales, la normalización de datos y selección de funciones, después de la selección de funciones, el modelo se implementó y las salidas se

producen en forma de probabilidades o una clase, el siguiente paso fue encontrar cuan eficiente es el modelo usando pruebas de conjunto de datos. Para la evaluación de la clasificación se ocuparon diferentes métricas como exactitud, recuerdo, precisión, puntuación F-1 y AUC-ROC de la curva. Se evaluó el rendimiento de 9 modelos de aprendizaje automático con técnicas de selección de funciones, en los resultados se observó que Bosques Aleatorios y Árboles de decisión, consiguieron exactitud del 84.86% y XGBoost logró la exactitud más alta de 88.15% con el 0.88 de precisión, 0.88 de recuerdo y una calificación F1 del 0.88, la exactitud más baja del 74.34% se obtuvo por el modelo de clasificación Bayesiano Ingenuo.

## 2.2 Análisis comparativo

A continuación, se muestra la tabla 2.1 donde se observa la información de los artículos más relevantes para el desarrollo de la tesis, con el objetivo de comparar similitudes y diferencias para su análisis.

**Tabla 2.1 Análisis comparativo de los artículos relacionados.**

| Artículo                    | Problema                                                                                                             | Contribución                                                                                                                                     | Tecnología                                                      | Resultados                                                                                                                                | Estado     |
|-----------------------------|----------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------|------------|
| Orozco-Arroyave et al. [24] | Falta de herramientas para evaluación de las deficiencias del habla en pacientes con enfermedad de Parkinson.        | Análisis de señales patológicas del habla.                                                                                                       | ASR, Máquinas de Vector Soporte, Regresor de Vector de Soporte. | Se desarrolló NeuroSpeech que clasifica el nivel de disartria de un paciente de enfermedad de Parkinson.                                  | Terminado. |
| Hyder et al. [25]           | Falta de evidencia en la correlación neuronal del procesamiento sintáctico en pacientes con enfermedad de Parkinson. | Técnicas que analizan la conectividad funcional dentro de las redes corticales activas durante el procesamiento automático del lenguaje hablado. | Regresión Lineal, MEG, MNE-Python 0.19.                         | Para la clasificación de enfermedad de Parkinson a través del análisis de los verbos de acción, se obtuvo una predicción correcta de 78%. | Terminado  |

| Artículo               | Problema                                                                                                  | Contribución                                                                                                                                                                 | Tecnología                                                 | Resultados                                                                                                     | Estado    |
|------------------------|-----------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------|-----------|
| Mostafa et al. [26]    | Determinar que método tiene un mejor desempeño para evaluar si un paciente tiene enfermedad de Parkinson. | Análisis de métodos para diagnosticar enfermedad de Parkinson a través de trastornos de la voz.                                                                              | Árboles de decisión, Bayesiano Ingenuo y Redes Neuronales. | El método de Árboles de decisión obtuvo la mayor precisión de clasificación de 91.63%                          | Terminado |
| Locke et al. [29]      | Falta de información sobre el Procesamiento de Lenguaje Natural y su uso en EHRs                          | Conocimiento sobre el Procesamiento de Lenguaje Natural, reglas, usos, categorías, limitaciones, futuras aplicaciones.                                                       | Procesamiento de Lenguaje Natural                          | Se obtuvo una revisión del estado actual del Procesamiento de Lenguaje Natural aplicado en el contexto médico. | Terminado |
| Novotný et al. [31]    | Falta de clasificadores de enfermedad de Parkinson que tomen en cuenta las funciones de la articulación   | Un algoritmo que clasifica enfermedad de Parkinson y pacientes control a través de funciones articulatorias.                                                                 | Máquinas de Vector Soporte                                 | Se obtuvo una clasificación de enfermedad de Parkinson con exactitud de 88%.                                   | Terminado |
| Chronowski et al. [35] | No existe una prueba antemortem para el diagnóstico enfermedad de Parkinson.                              | Se demostró que el preentrenamiento mejora el rendimiento de la clasificación y el afinamiento preciso de partes convolucionales degrada el rendimiento de la clasificación. | Deep Learning<br>Wav2vec 2.0<br>GRU                        | La predicción obtuvo un 97.92% de precisión en la clasificación de enfermedad de Parkinson.                    | Terminado |

| Artículo              | Problema                                                                                          | Contribución                                                                                                                                                          | Tecnología                                                                                                                                                                      | Resultados                                                                                   | Estado    |
|-----------------------|---------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------|-----------|
| Pappagari et al. [36] | Falta de evaluaciones del discurso y lenguaje objetivos y repetitivos en enfermedad de Alzheimer. | Se presentó un acercamiento automático para detectar enfermedad de Alzheimer y predecir MMSE mediante señales de discurso y sus transcripciones.                      | Redes Neuronales Profundas, x-vectors, BERT, Regresor de Vector de Soporte, GBR.                                                                                                | Se obtuvo una exactitud del 81.48% en la detección de enfermedad de Alzheimer.               | Terminado |
| Nogales et al. [37]   | Falta de evaluaciones para determinar enfermedad de Parkinson a usando EGGs y BERT.               | Se aplicó el modelo BERT del campo de Procesamiento de Lenguaje Natural a EEGs para desarrollar un método no invasivo para el diagnóstico de enfermedad de Parkinson. | BERT, EGGs, Procesamiento de Lenguaje Natural.                                                                                                                                  | Como resultado se obtuvo una exactitud del 93.45% al diagnosticar enfermedad de Parkinson.   | Terminado |
| Frid et al. [39]      | Falta de sistemas automáticos para el diagnóstico de enfermedad de Parkinson.                     | Un sistema automático que analiza las grabaciones de sujetos para determinar si son sanos o tienen enfermedad de Parkinson.                                           | Máquinas de Vector Soporte, C-Clasificador de Vectores de Soporte                                                                                                               | Se obtuvo un promedio de precisión de resultados del 81.8%.                                  | Terminado |
| Nissar et al. [40]    | Falta del diagnóstico de enfermedad de Parkinson a través de un modelo con XGBoost.               | Un sistema para la detección de enfermedad de Parkinson a través de técnicas aprendizaje automático .                                                                 | Deep Learning XGBoost, Regresión Linear, Bayesiano Ingenuo, K-Vecinos más Cercanos, Bosques Aleatorios, Árboles de decisión, Máquinas de Vector Soporte y Perceptrón Multicapa. | Se obtuvo una clasificación con una precisión del 95.39% por voz de enfermedad de Parkinson. | Terminado |

Por medio del análisis de los trabajos antes mencionados se determinó que, el desarrollo de sistemas para la detección temprana de enfermedad de Parkinson por medio de técnicas de Procesamiento de Lenguaje Natural con los más altos puntajes de precisión es a través del uso de técnicas de aprendizaje automático.

## **2.3 Solución propuesta**

Teniendo en cuenta las ventajas, desventajas, costos y beneficios de las diferentes tecnologías de desarrollo disponibles para cada elemento del módulo, se diseñó la siguiente propuesta como la solución más adecuada. A continuación, se describen cada una de las tecnologías consideradas en cada nivel del módulo.

### **2.3.1 Tecnologías del entorno de desarrollo y despliegue**

#### **2.3.1.1 Visual Studio Code**

*Visual Studio Code* es un editor de código optimizado con soporte para operaciones de desarrollo como depuración, ejecución de tareas y control de versiones. Su objetivo es proporcionar sólo las herramientas que un desarrollador necesita para un ciclo rápido de código-construcción depuración y deja los flujos de trabajo más complejos para IDEs más completos [41], lo que lo convierte en una herramienta flexible y eficiente, adaptándose fácilmente a distintas necesidades y etapas.

#### **2.3.1.2 Docker Desktop**

*Docker Desktop* es una aplicación que se instala con un solo clic en entornos Mac, Linux o Windows que permite crear, compartir y ejecutar aplicaciones y microservicios en contenedores. Proporciona una interfaz gráfica de usuario sencilla que permite gestionar contenedores, aplicaciones e imágenes desde el ordenador [42], siendo así una herramienta ideal para simplificar el desarrollo y despliegue de proyectos en contenedores, facilitando la colaboración y administración en entornos locales.

### 2.3.2 Tecnologías de la capa de presentación e integración

En esta sección se presentan las tecnologías propuestas, con un enfoque en el diseño eficiente de interfaces gráficas y la optimización de la experiencia del usuario. Esta capa tecnológica integra herramientas avanzadas que facilitan la creación de interfaces interactivas, dinámicas y visualmente atractivas, además de incluir mecanismos interactivos que permiten la comunicación fluida con los servicios del módulo correspondiente.

#### 2.3.2.1 TypeScript

*TypeScript* es un comparador estático de tipos, comprueba si hay errores en un programa antes de ejecutarlo, también es un súper conjunto tipado lo que significa añade reglas sobre cómo pueden utilizar los diferentes tipos de valores [43], convirtiéndolo en una herramienta poderosa para detectar errores temprano y mejorar la calidad de código en proyectos complejos, facilitando el mantenimiento y escalabilidad del desarrollo.

#### 2.3.2.2 Angular

*Angular* es una plataforma de desarrollo, construida sobre *TypeScript*. Incluye un marco de trabajo basado en componentes para construir aplicaciones web escalables, una colección de librerías bien integradas que cubren una amplia variedad de características, incluyendo enrutamiento, gestión de formularios, comunicación cliente-servidor, un conjunto de herramientas para desarrolladores que le ayudan a desarrollar, compilar, probar y actualizar el código [44].

#### 2.3.2.3 IONIC

*Ionic* es una plataforma para crear y desplegar aplicaciones móviles modernas y micro experiencias frontales [45].

#### 2.3.2.4 PHP

PHP (*Hypertext Preprocessor*, Preprocesador de Hypertexto) es un lenguaje de código abierto muy popular especialmente adecuado para el desarrollo web y que se incrusta en HTML [46],

carga su procesamiento en el lado del servidor y permite una rápida integración con sistemas gestores de bases de datos.

### 2.3.3 Tecnologías de la capa de servicios

En esta sección se destacan las tecnologías clave orientadas a la interpretación y clasificación precisa de datos, integrando elementos que permiten la incorporación de servicio altamente estables y eficientes. Esta capa incluye los recursos necesarios para la recepción, procesamiento y almacenamiento de la información del módulo, así como la gestión adecuada de los procesos de inteligencia artificial requeridos para la clasificación de la enfermedad de Parkinson.

En esta sección se mencionan las tecnologías clave enfocadas en la correcta interpretación y clasificación de datos mediante elementos que permiten la integración de servicios altamente escalables y eficientes. Esta capa incorpora las tecnologías necesarias para recibir, procesar y almacenar la información del módulo, así como también la correcta gestión de los procesos de aprendizaje automático requeridos para la clasificación de la enfermedad de Parkinson.

#### 2.3.3.1 Python

*Python* es un lenguaje de programación simple pero potente con una excelente funcionalidad para el procesamiento de datos lingüísticos, tiene una curva de aprendizaje poco profunda, su sintaxis y semántica son transparentes y tiene una buena funcionalidad de manejo de cadenas. Como lenguaje interpretado, *Python* facilita la exploración interactiva. Como lenguaje orientado a objetos, *Python* permite encapsular y reutilizar datos y métodos fácilmente. Como lenguaje dinámico, *Python* permite agregar atributos a objetos sobre la marcha y permite escribir variables dinámicamente, lo que facilita un desarrollo rápido. *Python* viene con una extensa biblioteca estándar, que incluye componentes para programación gráfica, procesamiento numérico y conectividad web, *Python* se utiliza mucho en la industria, la investigación científica y la educación en todo el mundo [8] A menudo se elogia a *Python* por la forma en que facilita la productividad, la calidad y la capacidad de mantenimiento del software, por la gran documentación, funciones, bibliotecas y herramientas para el desarrollo de aplicaciones de Procesamiento de Lenguaje Natural con *Python* se encontró que *Python* es la opción de lenguaje de programación más viable.

### 2.3.3.2 FastAPI

A pesar de ser un marco de trabajo rápido y moderno, *FastAPI* no incluye por defecto una capa de base de datos integrada ni una biblioteca de formularios [47], sin embargo, su diseño basado en estándares como OpenAPI y JSON Schema, junto con su integración nativa con bibliotecas de teceros como SQLAlchemy, Pydantic y Typer, lo convierten en una opción ideal para construir aplicaciones escalables, eficientes y con validaciones automáticas de datos.

### 2.3.3.3 Scikit-Learn

*Scikit-Learn* es una biblioteca de código abierto enfocada en la implementación fácil y rápida de modelos de aprendizaje automático en el lenguaje de programación *Python*, se presenta como herramienta de gran afinidad en el estudio de la enfermedad de Parkinson, gracias a su directa y amplia integración con los modelos de clasificación de instancias, así como también su optimización de procesos de análisis que mejora la eficacia de los algoritmos mediante la integración de código en C a través de la biblioteca *Cython* y soporte de variaciones en los métodos SVM [48].

## 2.3.4 Tecnologías de la capa de persistencia

Esta sección abarca las tecnologías que garantizan el almacenamiento seguro y confiable de la información. Esta capa incluye sistemas de bases de datos relacionales que proporcionan alta escalabilidad y flexibilidad, adaptándose al crecimiento progresivo y a las demandas históricas del proyecto.

### 2.3.4.1 MySQL

MySQL es un sistema de gestión de bases de datos SQL de código abierto popular, está desarrollado, distribuido y soportado por Oracle Corporation [49], por lo que se cuenta con amplia documentación y es una solución confiable y de alto rendimiento.

### 2.3.5 Justificación de la solución

La solución propuesta se centra en el análisis exhaustivo de las ventajas y desventajas de las tecnologías disponibles, evaluando su idoneidad para cada uno de los componente del módulo en desarrollo, para la capa de presentación e integración, se ha seleccionado *TypeScript* como lenguaje principal, aprovechando su paradigma orientado a objetos y tipado estático que compila a *JavaScript*, lo cual asegura un alto rendimiento y estabilidad en el código, esta implementación se lleva a cabo con los marcos de trabajo *Ionic* y *Angular*, tecnologías que ofrecen un alto nivel de rendimiento y escalabilidad, además de proporcionar herramientas esenciales para el desarrollo de aplicaciones web intuitivas y de fácil interacción para el usuario final. Asimismo, la capacidad avanzada de gestión de datos posiciona a *PHP* como una herramienta eficaz para la comunicación entre los servicios y el sistema de persistencia., en la capa de servicios, se ha optado por *Python* como lenguaje principal, dada su amplia adopción en el ámbito de la inteligencia artificial. Combinado con *FastAPI*, una herramienta altamente versátil y fácil de usar, *Python* permite la integración con múltiples herramientas y es ideal para procesar grandes volúmenes de datos y consultas a través de servicios REST API, por su parte, *Scikit-Learn* ha sido seleccionada como biblioteca de aprendizaje automático, gracias a su capacidad para soportar una amplia gama de algoritmos de clasificación , lo que convierte en una solución confiable para la gestión de clasificadores de información, finalmente, *MySQL* se eligió como el sistema gestor de base de datos principal debido a su alta estabilidad , fiabilidad y rendimiento en la gestión de grandes volúmenes de datos, proporcionando una gestión optima de recursos, estas herramientas son esenciales para asegurar la integración y disponibilidad de la información, consolidando una infraestructura sólida y escalable.

### Capítulo 3. Aplicación de la metodología

En este capítulo se presenta el desarrollo del módulo y aplicación de las tecnologías propuestas a través de cuatro fases (Análisis, Diseño, Desarrollo, Pruebas). A continuación, se describe cada una de ellas:

**Análisis:** Muestra los requerimientos y necesidades del módulo, identificando componentes clave, sus relaciones, y definiendo el alcance del proyecto, metas y objetivos.

**Diseño:** Presenta el diseño de la base de datos, la propuesta de interfaz gráfica y el diseño arquitectónico para la implementación del módulo.

**Desarrollo:** Muestra las interfaces desarrolladas y describe el módulo de clasificación implementado.

**Pruebas:** Incorpora mendicante casos de estudio los resultados de funcionalidad y rendimiento del módulo implementado

En la figura 3.1 se muestra el flujo de trabajo a recorrer durante la implementación de la metodología.




Figura 3.1 Metodología de desarrollo.

#### 3.1 Análisis

En esta sección, se realiza un análisis exhaustivo de los conceptos fundamentales para el desarrollo de la solución propuesta, para ello, identificaron las características necesarias para el correcto funcionamiento del módulo, estableciendo los requisitos funcionales, no funcionales y los casos de uso para la interacción con el módulo.

### 3.1.1 Requerimientos

En esta sección se describen los requisitos funcionales del módulo.

#### **Pronósticos**

- El usuario tiene la funcionalidad de crear pronósticos para su consulta.
- El usuario cuenta con la funcionalidad de enviar / registrar un pronóstico.
- El usuario tiene la funcionalidad de consultar los pronósticos realizados a los pacientes.
- El sistema automatiza el procesamiento de los ejercicios ingresadas para su clasificación con el modelo de análisis.
- El sistema automatiza el registro de resultados en el modelo de persistencia una vez obtenido el resultado de análisis.

#### **Ejercicios**

- Durante la consulta de ejercicios el sistema tiene acceso a la visualización de cada ejercicio desarrollado y la evaluación correspondiente.
- Al principio de la implementación de los ejercicios, el sistema presenta un conjunto de ejercicios en pantalla para su aplicación.

### 3.1.2 Casos de uso

A continuación, se presentan los casos de uso para cada contexto contemplado en el desarrollo del módulo.

Ejercicios




Figura 3.2 Diagrama de casos de uso del contexto Ejercicios.

| Caso de uso     | Consultar catálogo                                                                                        | Contexto | Ejercicios |
|-----------------|-----------------------------------------------------------------------------------------------------------|----------|------------|
| Descripción     | Permite al actor visualizar los tipos de ejercicios (fonación, lecturas de texto, repetición de palabras) |          |            |
| Actor           | Usuario                                                                                                   |          |            |
| Relaciones      | Caso de uso: [Ejercicios.Realizar]                                                                        |          |            |
| Precondiciones  | Estar registrado en el sistema                                                                            |          |            |
| Postcondiciones | NA                                                                                                        |          |            |

| Caso de uso     | Seleccionar ejercicio                                                                           | Contexto | Ejercicios |
|-----------------|-------------------------------------------------------------------------------------------------|----------|------------|
| Descripción     | Permite al actor seleccionar el ejercicio (fonación, lecturas de texto, repetición de palabras) |          |            |
| Actor           | Usuario                                                                                         |          |            |
| Relaciones      | Caso de uso: [Ejercicios. Seleccionar]                                                          |          |            |
| Precondiciones  | Seleccionar el tipo de ejercicio a realizar                                                     |          |            |
| Postcondiciones | NA                                                                                              |          |            |

|                 |                                                                 |          |            |
|-----------------|-----------------------------------------------------------------|----------|------------|
| Caso de uso     | Realizar ejercicio de fonación                                  | Contexto | Ejercicios |
| Descripción     | Permite al actor realizar un ejercicio de fonación de una vocal |          |            |
| Actor           | Usuario                                                         |          |            |
| Relaciones      | Caso de uso: [Ejercicios.Seleccionar] [Seleccionar.realizar]    |          |            |
| Precondiciones  | Seleccionar la fonación de una vocal                            |          |            |
| Postcondiciones | Estado del ejercicio: Finalizado                                |          |            |

|                 |                                                                 |          |            |
|-----------------|-----------------------------------------------------------------|----------|------------|
| Caso de uso     | Realizar ejercicio de lectura                                   | Contexto | Ejercicios |
| Descripción     | Permite al actor realizar un ejercicio de fonación de una vocal |          |            |
| Actor           | Usuario                                                         |          |            |
| Relaciones      | Caso de uso: [Ejercicios.Seleccionar] [Seleccionar.Realizar]    |          |            |
| Precondiciones  | Seleccionar la fonación de una vocal                            |          |            |
| Postcondiciones | Estado del ejercicio: Finalizado                                |          |            |

|                 |                                                                 |          |            |
|-----------------|-----------------------------------------------------------------|----------|------------|
| Caso de uso     | Realizar ejercicio de repetición                                | Contexto | Ejercicios |
| Descripción     | Permite al actor realizar un ejercicio de fonación de una vocal |          |            |
| Actor           | Usuario                                                         |          |            |
| Relaciones      | Caso de uso: [Ejercicios.Seleccionar] [Seleccionar.Realizar]    |          |            |
| Precondiciones  | Seleccionar la fonación de una vocal                            |          |            |
| Postcondiciones | Estado del ejercicio: Finalizado                                |          |            |

|                 |                                                                                    |          |            |
|-----------------|------------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Almacenar datos del ejercicio                                                      | Contexto | Ejercicios |
| Descripción     | Almacena los datos del ejercicio en la base de datos                               |          |            |
| Actor           | Sistema                                                                            |          |            |
| Relaciones      | Caso de uso: [Ejercicios.Seleccionar] [Seleccionar.Realizar]                       |          |            |
| Precondiciones  | Finalizar el ejercicio de voz (fonación, lectura de texto, repetición de palabras) |          |            |
| Postcondiciones | Estado del ejercicio: Almacenado con éxito                                         |          |            |

Pronóstico




Figura 3.3 Diagrama de casos de uso del contexto Pronóstico.

|                 |                                                                                   |          |            |
|-----------------|-----------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Visualizar ejercicios                                                             | Contexto | Pronóstico |
| Descripción     | Visualiza los datos de los ejercicios del paciente                                |          |            |
| Actor           | Usuario                                                                           |          |            |
| Relaciones      | Caso de uso: [Visualizar. Ejercicios]                                             |          |            |
| Precondiciones  | Finalizar 1 ejercicio de voz (fonación, lectura de texto, repetición de palabras) |          |            |
| Postcondiciones | NA                                                                                |          |            |

|                 |                                                                                                  |          |            |
|-----------------|--------------------------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Seleccionar realizar pronostico                                                                  | Contexto | Pronóstico |
| Descripción     | Muestra un modal para seleccionar los audios a procesar                                          |          |            |
| Actor           | Usuario                                                                                          |          |            |
| Relaciones      | Caso de uso: [Visualizar. Ejercicios] [Visualizar. Realizar]                                     |          |            |
| Precondiciones  | Finalizar 2 o más tipos de ejercicio de voz (fonación, lectura de texto, repetición de palabras) |          |            |
| Postcondiciones | Asignar valores derivados del cálculo de pronóstico                                              |          |            |

|                 |                                                                                                  |          |            |
|-----------------|--------------------------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Seleccionar ejercicios                                                                           | Contexto | Pronóstico |
| Descripción     | Dentro del modal permite al usuario seleccionar los ejercicios para ser procesados.              |          |            |
| Actor           | Usuario                                                                                          |          |            |
| Relaciones      | Caso de uso: [Visualizar. Ejercicios] [Visualizar.Realizar] [Visualizar. Seleccionar]            |          |            |
| Precondiciones  | Finalizar 2 o más tipos de ejercicio de voz (fonación, lectura de texto, repetición de palabras) |          |            |
| Postcondiciones | Asignar valores derivados del cálculo de pronóstico                                              |          |            |

|                 |                                                                                                    |          |            |
|-----------------|----------------------------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Procesar ejercicios                                                                                | Contexto | Pronóstico |
| Descripción     | Permite al actor procesar cada uno de los ejercicios recibidos en la prueba para su interpretación |          |            |
| Actor           | Sistema                                                                                            |          |            |
| Relaciones      | Caso de uso: [Visualizar.Envíar],[ Visualizar.Registrar]                                           |          |            |
| Precondiciones  | 2 o más tipos de ejercicios se encuentran completados y enviados para ser procesados.              |          |            |
| Postcondiciones | Los resultados cuentan con su registro correspondiente en el modelo de persistencia                |          |            |

|                 |                                                                                            |          |            |
|-----------------|--------------------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Registrar pronóstico                                                                       | Contexto | Pronóstico |
| Descripción     | Permite al actor registrar los resultados obtenidos del pronóstico realizado               |          |            |
| Actor           | Sistema                                                                                    |          |            |
| Relaciones      | Caso de uso: [Pacientes.Registrar]                                                         |          |            |
| Precondiciones  | Ejecución correcta del cálculo del pronóstico determinando los resultados de clasificación |          |            |
| Postcondiciones | El estado de la prueba se representa como: FINALIZADO                                      |          |            |

|                 |                                                                                     |          |            |
|-----------------|-------------------------------------------------------------------------------------|----------|------------|
| Caso de uso     | Mostrar historial de pronósticos                                                    | Contexto | Pronóstico |
| Descripción     | Mostrar los pronósticos realizados a lo largo del tiempo                            |          |            |
| Actor           | Sistema                                                                             |          |            |
| Relaciones      | Caso de uso: [Visualizar. Pronóstico]                                               |          |            |
| Precondiciones  | Los resultados cuentan con su registro correspondiente en el modelo de persistencia |          |            |
| Postcondiciones | NA                                                                                  |          |            |

### 3.1.3 Características de la aplicación

El módulo se diseñó para facilitar el diagnóstico temprano de la enfermedad de Parkinson. A través de una serie de ejercicios de voz (vocales, lectura, repetición), el sistema recopila muestras de audio que son analizadas mediante técnicas avanzadas de procesamiento de señal, estas técnicas permiten extraer características acústicas específicas relacionadas con la enfermedad de Parkinson, como Jitter que se define como el parámetro de variación de la frecuencia de ciclo a ciclo, Shimmer relates a la variación de la amplitud de la onda del sonido [50] y variación en la frecuencia fundamental resultado de la variación de la velocidad de vibración de las cuerdas vocales, está relacionada perceptualmente con el tono vocal [51], los datos obtenidos se procesan por modelos de aprendizaje automático entrenados para clasificar a los usuarios como sanos o con riesgo de desarrollar la enfermedad, proporcionando un pronóstico personalizado y un registro detallado de la evolución de las características vocales a lo largo del tiempo.

### 3.1.4 Conjunto de datos de atributos de voz para la detección de EP

Considerando que el módulo trabaja en conjunto con un servicio para clasificar datos, se identificó qué conjuntos de datos son los más adecuados para usar como modelos de entrenamiento y prueba en la clasificación de ejercicios para detectar la enfermedad de Parkinson. A continuación, se presentan el conjunto de datos seleccionado:

#### Parkinson's Data Set

El conjunto de datos titulado “Parkinson's Data Set” [52] se diseñó en el trabajo de [11] para determinar si un paciente se encuentra sano o tiene enfermedad de Parkinson tomando en cuenta los atributos relacionados con la detección de la disfonía, estos atributos se muestran en la Tabla 3.1, el conjunto de datos consiste en 195 registros de fonaciones vocales de 31 hombres y mujeres, de los cuales 23 se diagnosticaron con la Enfermedad de Parkinson, a continuación, se enlistan los atributos del Dataset.

*Tabla 3.1 Atributos en el conjunto de datos Parkinson Data Set.*

| Parkinson Data Set |                  |                                                          |
|--------------------|------------------|----------------------------------------------------------|
| #                  | Atributo         | Descripción                                              |
| 1                  | Name             | nombre del sujeto ASCII y numero de grabación            |
| 2                  | MDVP: Fo (Hz)    | Promedio de frecuencia fundamental vocal                 |
| 3                  | MDVP:Fhi(Hz)     | Máximo de frecuencia fundamental vocal                   |
| 4                  | MDVP:Flo(Hz)     | Mínimo de frecuencia fundamental vocal                   |
| 5                  | MDVP:Jitter(%)   | Varias medidas de variación en la frecuencia fundamental |
| 6                  | MDVP:Jitter(Abs) |                                                          |
| 7                  | MDVP:RAP         |                                                          |
| 8                  | MDVP:PPQ         |                                                          |
| 9                  | Jitter:DDP       |                                                          |
| 10                 | MDVP:Shimmer     | Varias medidas de variación en amplitud                  |
| 11                 | MDVP:Shimmer(dB) |                                                          |
| 12                 | Shimmer:APQ3     |                                                          |
| 13                 | Shimmer:APQ5     |                                                          |
| 14                 | MDVP:APQ         |                                                          |
| 15                 | Shimmer:DDA      |                                                          |

| Parkinson Data Set |          |                                                                       |
|--------------------|----------|-----------------------------------------------------------------------|
| #                  | Atributo | Descripción                                                           |
| 16                 | NHR      | 2 medidas de relación entre ruido a los componentes tonales en la voz |
| 17                 | HNR      |                                                                       |
| 18                 | Status   | Estado de salud del sujeto (1) – Parkinson's (0) – Saludable          |
| 19                 | RPDE     | 2 medidas de complejidad dinámica no lineal                           |
| 20                 | D2       |                                                                       |
| 21                 | DFA      | Exponente de escala fractal de señal                                  |
| 22                 | spread1  | 3 medidas no lineales de variación de frecuencia fundamental          |
| 23                 | spread2  |                                                                       |
| 24                 | PPE      |                                                                       |

Utilizando los atributos de la tabla los investigadores lograron conducir a un rendimiento general de clasificación correcta del 91.4%.

### 3.1.5 Selección de algoritmos de clasificación

Como parte fundamental del módulo, se llevó a cabo una evaluación comparativa de 11 algoritmos de clasificación para la detección de la Enfermedad de Parkinson por voz, para este análisis, se escogieron aquellos algoritmos que, de acuerdo con la investigación previa, demostraron los mejores desempeños, la evaluación se llevó a cabo en un entorno controlado utilizando un conjunto de datos y métricas de evaluación uniformes. A continuación, se enlistan los algoritmos utilizados:

- **Máquina de vectores de soporte:** La máquina de vector soporte implementa la siguiente idea: mapea los vectores  $x$  de entrada en una dimensión elevada de espacio de características  $Z$  a través de algún mapeo no lineal, elegido previamente. En este espacio se construye un hiperplano de separación óptimo [53].
- **K-Vecinos más cercanos:** k-NN es un tipo de aprendizaje basado en instancias (también conocido como aprendizaje perezoso), lo que significa que el proceso de entrenamiento solo

almacena las muestras y todo el coste computacional se induce en el proceso de prueba para encontrar los  $k$  vecinos más cercanos [54].

- **Clasificación Naive-Bayes:** El clasificador Bayes ingenuo se aplica a tareas de aprendizaje en las que cada instancia  $x$  se describe mediante una conjunción de valores de atributo y en las que la función objetivo  $f(x)$  puede tomar cualquier valor de un conjunto finito  $V$  [55].
- **Regresión Logística:** Es un clasificador de aprendizaje automático supervisado que extrae características de valor real de la entrada, multiplica cada una por un peso, las suma y pasa la suma por una función sigmoidea para generar una probabilidad [56].
- **Arboles de decisión:** Es un modelo de aprendizaje supervisado utilizado para clasificación y regresión. Este modelo organiza las decisiones en una estructura de árbol, donde cada nodo representa una prueba sobre una característica (o atributo), cada rama representa el resultado de la prueba y cada hoja representa una decisión o clase.
- **AdaBoost:** Adaptive Boosting es un algoritmo de aprendizaje supervisado que mejora la precisión de los modelos mediante el ensamblaje de múltiples clasificadores débiles (modelos que apenas superan el azar) en un clasificador fuerte.
- **Gradient Boosting** es un algoritmo de aprendizaje supervisado utilizado principalmente para problemas de clasificación y regresión, como técnica de Boosting, Gradient Boosting crea un modelo fuerte a partir de múltiples modelos débiles (generalmente arboles de decisión de baja profundidad), que se entrenan secuencialmente, cada uno corrigiendo los errores del anterior, a diferencia de AdaBoost, que se centra en reponderar las observaciones difíciles de clasificar, Gradient Boosting minimiza directamente el error residual en cada paso, ajustándose a la diferencia (gradiente) entre las predicciones actuales y valores reales.

- **XGBoost:** Extreme Gradient Boosting, es una implementación optimizada del algoritmo de Gradient Boosting tiene popularidad debido a su eficiencia, velocidad y rendimiento superior en problemas de clasificación y regresión.
- **Random Forest** es un algoritmo de aprendizaje automático que pertenece a la familia de métodos de ensamble y se utiliza para problemas de clasificación y regresión.
- **Bagged Decision Trees o Bagging:** Bootstrap Aggregating es una técnica de aprendizaje de ensamble que implica entrenar múltiples árboles de decisión (o modelos débiles en general) de manera independiente y luego combinar sus predicciones para mejorar la precisión y reducir el sobreajuste, Bagging se basa en la idea de generar diversidad entre los modelos mediante el uso de diferentes muestras del conjunto de datos, lo cual ayuda a reducir la varianza del modelo final.
- **Bagged SVM:** Es un método de aprendizaje automático que combina la máquina de vectores de soporte con baggin (Broostrap Aggregating), en este método, se crean múltiples subconjuntos de datos de entrenamiento mediante muestreo con reemplazo, luego, un modelo SVM se entrena en cada subconjunto, y al final, las predicciones de todos los modelos se combinan, generalmente mediante votación para clasificación o promedio para regresión, esto ayuda a reducir la varianza y mejorar la estabilidad y precisión del modelo.

En la tabla 3.2 se presenta una evaluación comparativa de 11 algoritmos de Inteligencia Artificial aplicados al conjunto de datos Parkinson Disease Data Set, en donde se analizan métricas clave como exactitud, precisión, sensibilidad, especificidad, F1-Score y AUC para determinar el algoritmo con mejor desempeño en la detección de la Enfermedad de Parkinson.

*Tabla 3.2 Comparación de las métricas de los algoritmos implementados en el conjunto de datos Parkinson's Data Set.*


| Algoritmo  | Exactitud | Precisión | Sensibilidad | Especificidad | F1-Score | AUC    |
|------------|-----------|-----------|--------------|---------------|----------|--------|
| <b>SVM</b> | 87.18     | 90.63     | 93.55        | 62.50         | 92.06    | 0.8185 |
| <b>KNN</b> | 76.92     | 92.31     | 77.42        | 75.00         | 84.21    | 0.8972 |


| Algoritmo                | Exactitud | Precisión | Sensibilidad | Especificidad | F1-Score | AUC    |
|--------------------------|-----------|-----------|--------------|---------------|----------|--------|
| <b>NB</b>                | 61.54     | 100.00    | 51.61        | 100.00        | 68.09    | 0.8790 |
| <b>LR</b>                | 82.05     | 90.00     | 87.10        | 62.50         | 88.52    | 0.8347 |
| <b>DT</b>                | 76.92     | 95.83     | 74.19        | 87.50         | 83.64    | 0.8085 |
| <b>AdaBoost</b>          | 87.18     | 93.33     | 90.32        | 75.00         | 91.80    | 0.9637 |
| <b>Gradient Boosting</b> | 82.05     | 92.86     | 83.87        | 75.00         | 88.14    | 0.9194 |
| <b>XGBoost</b>           | 87.18     | 96.43     | 87.10        | 87.50         | 91.53    | 0.9395 |
| <b>RF</b>                | 79.49     | 89.66     | 83.87        | 62.50         | 86.67    | 0.8931 |
| <b>Bagged DT</b>         | 76.92     | 89.29     | 80.65        | 62.50         | 84.75    | 0.8992 |
| <b>Bagged SVM</b>        | 84.62     | 87.88     | 93.55        | 50.00         | 90.63    | 0.8306 |


Con base en los resultados recopilados en la tabla 3.2, se concluye que el algoritmo XGBoost exhibe el mejor rendimiento global para la detección de la Enfermedad de Parkinson dentro del conjunto de datos Parkinson Data Set, este algoritmo demostró una exactitud del 87.18%, una precisión del 96.43%, una sensibilidad del 87.10%, una especificidad del 87.50%, un F1-Score del 91.53%, y un valor de área bajo la curva (AUC) de 0.9395, estas métricas combinadas indican que XGBoost es el algoritmo más efectivo entre los evaluados para identificar la Enfermedad de Parkinson en el conjunto de datos Parkinson Data Set.

Asimismo, se llevaron a cabo pruebas comparativas entre los clasificadores mediante el análisis de la curva ROC, la cual representa la relación entre la sensibilidad y la especificidad de cada modelo. La tabla 3.3 presenta en detalle los resultados obtenidos durante este análisis comparativo.

*Tabla 3.3 Resultados de la curva ROC.*







A través de un análisis del AUC (*Area Under Curve*, Area Bajo la Curva) ROC (*Receiver Operating Characteristic* o Característica Operativa del Receptor), se concluye como elección de algoritmo XGBoost, por ser más efectivo para la detección de la Enfermedad de Parkinson en el conjunto de datos Parkinson Disease Data Set, ya que este resultado representa la capacidad del modelo para distinguir entre las clases con precisión, lo que indica una mayor confiabilidad en a las predicciones.

### 3.2 Fase de Diseño

En esta sección se presenta el diseño de la arquitectura, detallando tanto su estructura como los fundamentos teóricos y gráficos derivados para el control de la información, también, se incluye el modelo de persistencia junto con el diseño de las interfaces gráficas.

#### 3.2.1 Arquitectura del módulo

Esta sección tiene como objetivo brindar una visión general de la arquitectura del módulo para la detección temprana de la Enfermedad de Parkinson explicando la interacción específica entre el módulo web y el modelo de clasificación entrenado para la identificación de parámetros clave. El flujo de trabajo comienza con un cliente web que aloja el módulo y permite su acceso al personal médico para la aplicación de pruebas relacionadas con la Enfermedad de Parkinson, este módulo cuenta con varias secciones operativas incluyendo la aplicación de nuevos estudios y el seguimiento de la evolución del paciente, centrándose en el historial de pruebas realizadas. Durante la aplicación de nuevos estudios el módulo en conjunto con las demás capas lógicas

recopila, procesan interpretan y recuperan los resultados obtenidos para su posterior seguimiento y monitoreo.

El proceso de obtención de datos en el módulo comienza con un micrófono que permite el ingreso de la señal de audio de voz del paciente para su digitalización, lo que permite al paciente realizar una serie de ejercicios de voz utilizando plantillas predefinidas. Los datos recolectados se envían a un servidor externo, donde el clasificador realiza las operaciones de procesamiento e interpretación correspondientes. Finalmente, los resultados se registran en la base de conocimiento para su posterior consulta y seguimiento.

El módulo está distribuido en una arquitectura de capas para proporcionar una solución de mayor escalabilidad, robustez y fácil mantenimiento. Durante el proceso de desarrollo se consideró el uso diferentes tecnologías para mejorar el rendimiento de los procesos, al igual que la implementación de medidas de seguridad que garanticen la integridad de los datos. La figura 3.4 describe la arquitectura establecida para el desarrollo del módulo del mismo modo, enumera las etiquetas (1-10) el flujo de trabajo principal “Clasificación de una prueba de voz”.




Figura 3.4 Arquitectura del módulo web para la detección temprana de la Enfermedad de Parkinson.

A continuación, se describe cada una de las capas integradas en la arquitectura.

- **Capa de presentación:** Esta es la interfaz gráfica principal de la aplicación web, diseñada para el uso del personal médico. Facilita la recopilación y el seguimiento de las pruebas realizadas, con un enfoque en la usabilidad y la presentación de información clara.
- **Capa de integración:** Esta capa está compuesta por varios módulos que se encargan de funciones específicas. El módulo de ejercicios recopila los audios de los pacientes durante las pruebas, utilizando un micrófono y una laptop, El módulo de seguimiento proporciona datos estadísticos relacionados con el historial de resultados de cada paciente. El módulo de resultados presenta los resultados registrados por el clasificador de manera fácil. Todos los datos interpretados se envían a la capa de servicios a través del módulo de integración.
- **Capa de servicios:** Esta capa incluye diversos módulos que definen los casos de uso para la predicción y consulta de estudios. En el proceso de predicción, se utilizan el módulo de extracción de características, que se enfoca en la lectura y análisis de instancias gráficas y el módulo de aprendizaje automático, que se encarga de la interpretación y clasificación de resultados mediante algoritmos previamente entrenados. El módulo de acceso a datos proporciona una interfaz de acceso a la capa de persistencia para el almacenamiento de datos.
- **Capa de persistencia:** Esta capa incorpora el sistema gestor de base de datos y la base de datos principal del módulo, encargados del control y almacenamiento de la información necesario para su posterior análisis y seguimiento.

### 3.2.2 Modelo de persistencia

En lo que respecta al diseño e implementación del modelo de persistencia para la integración de los diferentes componentes del módulo, se adoptó una estrategia modular y escalable, se optó por una arquitectura lógicamente distribuida. En la figura tal se presenta el esquema relacional del sistema el cual muestra la estructura de las relaciones de entidades involucradas. Este modelo asegura un diseño flexible y escalable, lo que garantiza la adaptabilidad a medida que este evolucione.




Figura 3.5 Esquema relacional de base de datos.

### 3.2.2.1 Diccionario de datos

En este apartado, se presenta el diccionario de datos que permite identificar y comprender todas las características integradas en el modelo de persistencia, este conjunto de información se utiliza para el manejo y gestión efectivos de los datos almacenados, garantizando una integración y funcionamiento óptimos del sistema.

- **Entidad:** PARKINSON.TIPOS. EJERCICIOS

**Descripción:** Entidad que almacena los datos requeridos para la clasificación de los diferentes tipos de ejercicios para el pronóstico de la enfermedad de Parkinson.

*Tabla 3.4 Diccionario de entidad "PARKINSON.TIPOS.EJERCICIOS"*

| Propiedad                | Descripción                                   | Tipo    | Longitud | Clave    | Valor |
|--------------------------|-----------------------------------------------|---------|----------|----------|-------|
| <b>id_tipo_ejercicio</b> | Identificador del registro                    | INTEGER | Default  | Primaria | -     |
| <b>nombre</b>            | Especifica el nombre del tipo de ejercicio    | VARCHAR | 25       | -        | -     |
| <b>descripción</b>       | Especifica los detalles del tipo de ejercicio | VARCHAR | 255      | -        | -     |
| <b>activo</b>            | Establece si el registro se encuentra activo  | TINYINT | default  | -        | 1     |

- **Entidad:** PARKINSON.TIPOS. PRUEBAS

**Descripción:** Entidad que almacena el conjunto de datos para la clasificación de pruebas de Parkinson.

*Tabla 3.5 Diccionario de entidad "PARKINSON.TIPOS.PRUEBAS"*

| Propiedad             | Descripción                             | Tipo    | Longitud | Clave    | Valor |
|-----------------------|-----------------------------------------|---------|----------|----------|-------|
| <b>id_tipo_prueba</b> | Identificador del registro              | INTEGER | Default  | Primaria | -     |
| <b>nombre</b>         | Especifica el nombre del tipo de prueba | VARCHAR | 25       | -        | -     |

| Propiedad          | Descripción                                   | Tipo    | Longitud | Clave | Valor |
|--------------------|-----------------------------------------------|---------|----------|-------|-------|
| <b>descripción</b> | Especifica los detalles del tipo de ejercicio | VARCHAR | 255      | -     | -     |
| <b>activo</b>      | Establece si el registro se encuentra activo  | TINYINT | default  | -     | 1     |

- **Entidad:** PARKINSON.CAT. EJERCICIOS

**Descripción:** Entidad que almacena el conjunto de datos para la clasificación de pruebas de Parkinson.

*Tabla 3.6 Diccionario de entidad "PARKINSON.CAT.EJERCICIOS"*

| Propiedad                | Descripción                                                            | Tipo    | Longitud | Clave    | Valor |
|--------------------------|------------------------------------------------------------------------|---------|----------|----------|-------|
| <b>id_ejercicio</b>      | Identificador del registro                                             | INTEGER | default  | Primaria | -     |
| <b>id_tipo_prueba</b>    | Especifica el dato de referencia al tipo de prueba al que pertenece    | INTEGER | default  | Foránea  | -     |
| <b>id_tipo_ejercicio</b> | Especifica el dato de referencia al tipo de ejercicio al que pertenece | VARCHAR | 255      | Foránea  | -     |
| <b>nombre</b>            | Especifica el nombre de la categoría de ejercicio al que pertenece     | VARCHAR | 30       | -        | -     |
| <b>recurso</b>           | Almacena información complementaria de las categorías de ejercicios    | BLOB    | -        | -        | -     |
| <b>activo</b>            | Establece si el registro se encuentra activo                           | TINYINT | default  | -        | 1     |

- **Entidad:** PARKINSON.PROC.PRUEBAS

**Descripción:** Entidad que almacena los pronósticos realizados a los usuarios

Tabla 3.7 Diccionario de entidad "PARKINSON.PROC.PRUEBAS"

| Propiedad             | Descripción                                                         | Tipo     | Longitud | Clave    | Valor |
|-----------------------|---------------------------------------------------------------------|----------|----------|----------|-------|
| <b>id_prueba</b>      | Identificador del registro                                          | VARCHAR  | 12       | Primaria | -     |
| <b>id_tipo_prueba</b> | Especifica el dato de referencia al tipo de prueba al que pertenece | INTEGER  | default  | -        | -     |
| <b>fecha</b>          | Fecha en que se realizó el pronóstico                               | DATETIME | -        | -        | -     |
| <b>tiempo</b>         | Tiempo que tardo en realizarse el pronóstico                        | INT      | -        | -        | 1     |
| <b>probabilidad</b>   | Almacena el tipo de probabilidad del pronóstico                     | VARCHAR  | 25       | -        | -     |
| <b>resultado</b>      | Almacena el porcentaje de probabilidad del pronóstico               | DECIMAL  | 5,2      | -        | 1     |

- **Entidad:** PARKINSON.PROC.DETALLES\_PRUEBAS

**Descripción:** Entidad que almacena los detalles de los ejercicios realizados a los usuarios

Tabla 3.8 Diccionario de entidad "PARKINSON.PROC.DETALLES\_PRUEBAS"

| Propiedad                | Descripción                                                    | Tipo    | Longitud | Clave    | Valor |
|--------------------------|----------------------------------------------------------------|---------|----------|----------|-------|
| <b>id_detalle_prueba</b> | Identificador del registro                                     | INTEGER | default  | Primaria | -     |
| <b>folio</b>             | Identifica el ejercicio                                        | VARCHAR | 50       | -        | -     |
| <b>id_ejercicio</b>      | Especifica el dato de referencia al ejercicio al que pertenece | INTEGER | default  | -        | -     |
| <b>tiempo</b>            | Tiempo que tomo el ejercicio en realizarse                     | INTEGER | default  | -        | -     |

| Propiedad           | Descripción                                                           | Tipo    | Longitud | Clave | Valor |
|---------------------|-----------------------------------------------------------------------|---------|----------|-------|-------|
| <b>muestra</b>      | Almacena el archivo binario obtenido en la realización del ejercicio  | BLOB    | default  | -     | -     |
| <b>resultado</b>    | Almacena el resultado obtenido del pronóstico                         | DECIMAL | 5,2      | -     | -     |
| <b>id_aplicador</b> | Especifica el dato de referencia al aplicador del ejercicio           | INTEGER | default  | -     | -     |
| <b>id_paciente</b>  | Especifica el dato de referencia al paciente que realiza el ejercicio | INTEGER | default  | -     | -     |
| <b>jitter</b>       | Almacena el valor de jitter en la muestra                             | DECIMAL | 5,2      | -     | -     |
| <b>shimmer</b>      | Almacena el valor de shimmer en la muestra                            | DECIMAL | 5,2      | -     | -     |
| <b>f0</b>           | Almacena el valor de la frecuencia fundamental en la muestra          | DECIMAL | 5,2      | -     | -     |
| <b>pronostico</b>   | Almacena el resultado del análisis de la muestra                      | VARCHAR | 50       | -     | -     |
| <b>precision</b>    | Almacena la precisión del pronóstico                                  | DECIMAL | 5,2      | -     | -     |

- **Entidad:** PRUEBAS\_DETALLES

**Descripción:** Entidad que almacena las relaciones entre los pronósticos y cada uno de los detalles de los ejercicios.

Tabla 3.9 Diccionario de entidad "PRUEBAS\_DETALLES"

| Propiedad                | Descripción                                                                 | Tipo    | Longitud | Clave   | Valor |
|--------------------------|-----------------------------------------------------------------------------|---------|----------|---------|-------|
| <b>id_prueba</b>         | Especifica el dato de referencia al identificador del pronostico            | VARCHAR | 12       | Foránea | -     |
| <b>id_detalle_prueba</b> | Especifica el dato de referencia al identificador del detalle del ejercicio | INTEGER | default  | Foránea | -     |

- **Entidad:** USUARIOS.REL.PACIENTES\_CUIDADORES

**Descripción:** Entidad que almacena las relaciones entre pacientes y cuidadores

Tabla 3.10 Diccionario de entidad "USUARIOS.REL.PACIENTES\_CUIDADORES"

| Propiedad          | Descripción                                                            | Tipo    | Longitud | Clave               | Valor |
|--------------------|------------------------------------------------------------------------|---------|----------|---------------------|-------|
| <b>id_paciente</b> | Especifica el dato de referencia al identificador del usuario paciente | INTEGER | default  | Primaria<br>Foránea | -     |
| <b>id_cuidador</b> | Especifica el dato de referencia al identificador del usuario cuidador | INTEGER | default  | Primaria<br>Foránea | -     |

- **Entidad:** USUARIOS.REL.PACIENTES\_MEDICOS

**Descripción:** Entidad que almacena las relaciones entre pacientes y médicos

Tabla 3.11 Diccionario de entidad "USUARIOS\_REL.PACIENTES\_MEDICOS"

| Propiedad          | Descripción                                                            | Tipo    | Longitud | Clave               | Valor |
|--------------------|------------------------------------------------------------------------|---------|----------|---------------------|-------|
| <b>id_paciente</b> | Especifica el dato de referencia al identificador del usuario paciente | INTEGER | default  | Primaria<br>Foránea | -     |
| <b>id_medico</b>   | Especifica el dato de referencia al identificador del usuario medico   | INTEGER | default  | Primaria<br>Foránea | -     |

### 3.2.3 Maquetación del modulo

A continuación, se muestran los modelos gráficos principales, con el objetivo de definir los aspectos clave para el desarrollo del módulo.

#### 3.2.3.1 Componentes personalizados

En este apartado se describe el diseño de los componentes personalizados creados para la aplicación, con el objetivo de mantener la coherencia visual, mejorar la usabilidad de la interfaz y facilitar la reutilización de elementos gráficos, optimizando así el proceso de desarrollo.

**Encabezado (Figura 3.6):** Este componente es una barra superior que está presente en cada sección del módulo. Su objetivo es orientar al usuario proporcionando información general sobre la selección activa.




Figura 3.6 Mockup – Componente – Encabezado

**Menú lateral (figura 3.7):** Este componente es un panel lateral que permite acceder a las distintas secciones del módulo.






Figura 3.7 Mockup - Componente - Menú lateral.

**Tarjeta de concepto (Figura 3.8):** Este componente es una tarjeta que muestra información rápida sobre un elemento específico, ofreciendo una vista previa útil de los elementos disponibles en la aplicación.




*Figura 3.8 Mockup - Componente - Tarjeta concepto.*

**Tarjeta estadística (Figura 3.9):** Este componente, en formato tarjeta, muestra información estadística sobre un elemento específico. Es una forma rápida y sencilla de visualizar resultados clave de un dato en el registro.



*Figura 3.9 Mockup - Componente - Tarjeta estadística.*

**Tarjeta de gráfico (Figura 3.10):** Este componente presenta un gráfico estadístico en formato de tarjeta, diseñado para ofrecer al usuario una visualización detallada de un conjunto de registros almacenados. Su propósito es facilitar el análisis posterior de los datos de manera eficiente y visualmente intuitiva.



*Figura 3.10 Mockup – Componente – Tarjeta de gráfico.*

**Tarjeta de gráfico compacto (Figura 3.11):** Al igual que la “tarjeta de gráfico”, este componente muestra un gráfico estadístico en formato de tarjeta, pero en una versión de datos, permitiendo su análisis posterior de manera ágil y eficiente.



*Figura 3.11 Mockup - Componente - Tarjeta de gráfico compacto.*

**Tarjeta de datos (Figura 3.12):** Este componente presenta conjunto complejo de datos en un formato tabular, haciéndola una opción eficiente para mostrar al usuario información estructurada y organizada en columnas, facilitando su análisis detallado.

Etiqueta

| Columna 1 | Columna 2 | Columna 3 | Columna 4 |
|-----------|-----------|-----------|-----------|
| Etiqueta  | Etiqueta  | Etiqueta  | Etiqueta  |
| Etiqueta  | Etiqueta  | Etiqueta  | Etiqueta  |
| Etiqueta  | Etiqueta  | Etiqueta  | Etiqueta  |
| Etiqueta  | Etiqueta  | Etiqueta  | Etiqueta  |

Figura 3.12 Mockup - Componente - Tarjeta de datos.

3.2.3.2 Inicio de sesión

En la figura 3.13 se muestra el modelo de acceso al módulo, el cual se basa en la autenticación mediante credenciales (nombre de usuario y contraseña).

EtiquetaEtiqueta

BIENVENIDO

Ingrese su usuario y contraseña para iniciar sesión

Usuario

Contraseña

Ingresar

Figura 3.13 Mockup - Interfaz de inicio de sesión.

### 3.2.3.3 Panel estadístico

Basado en el diseño mostrado, en la Figura 3.14, 3.15 y 3.16, correspondientes a las pantallas del “Panel principal”, “Expediente del paciente” y “Detalles de la prueba”, se propone una interfaz gráfica que incluya visualizaciones estadísticas para mostrar datos como:

- **Tarjeta informativa:** Proporciona información general de la sección correspondiente. En el caso del panel principal y del expediente del paciente, se incluyen los datos personales del usuario, Para la sección de detalles de las pruebas, se presentan los datos de identificación del registro asociado.
- **Tarjeta de conteo:** Ofrece un resumen global del registro mostrado. Por ejemplo, se visualiza el número total de pacientes en atención, el porcentaje de casos en estudio, el número de pruebas realizadas, entre otros indicadores clave.
- **Tarjeta de probabilidad:** Presenta un porcentaje general que refleja la probabilidad de padecimiento, basado en el análisis de todos los estudios realizados hasta el momento.
- **Gráfico histórico:** Permite visualizar el seguimiento cronológico de los datos, con el objetivo de comparar el progreso de los estudios registrados a lo largo del tiempo.
- **Gráfico de resultados:** Muestra una comparación relacional entre diferentes clasificadores de información, como el número de pacientes según género o edad, los resultados positivos y negativos de una prueba.




Figura 3.14 Mockup - Interfaz de panel estadístico (Principal)

Para las Figuras 3.15 y 3.16, correspondientes a las pantallas “Pacientes”, “Ejercicios del paciente”, “Historia del paciente” y “Detalles de los ejercicios de la prueba”, también se incluye:

- **Tabla de datos:** Presenta múltiples registros en formato tabular relacionados con la información reciente desde el mismo elemento.




Figura 3.15 Mockup -Interfaz de pacientes (Registros de los pacientes)




Figura 3.16 Mockup - Interfaz de los ejercicios realizados por el paciente.



Figura 3.17 Interfaz de la historia de pronósticos del paciente.



Figura 3.18 Interfaz de los detalles de los ejercicios de la prueba.

#### 3.2.3.4 Ejercicios de voz

Para la elaboración de los ejercicios de voz se tomaron en cuenta las configuraciones establecidas en los trabajos de [57], [58], [59], los cuales definen tres tipos de ejercicios: fonación, lectura y repetición de palabras. Basado en este diseño, se propone una interfaz gráfica que incluye los siguientes elementos para guiar y facilitar la interacción del usuario:

**Encabezado informativo:** Muestra el nombre completo del paciente que realiza el ejercicio, permitiendo una rápida identificación y personalización de la experiencia de usuario.

**Sección de instrucciones:** Contiene el texto detallado de las indicaciones que el paciente sigue para realizar el ejercicio correctamente. Esta sección facilita la comprensión de cada ejercicio mediante instrucciones claras y específicas.

**Indicador de tipo de ejercicio:** Justo debajo de las instrucciones, se especifica el tipo de ejercicio (fonación, lectura o repetición de palabras) en el que se encuentra el paciente, brindando un contexto rápido y sencillo sobre la actividad actual.

**Contador decrementable:** Visualiza el tiempo restante en el ejercicio, ayudando al paciente a gestionar el tiempo de manera efectiva y optimizar la duración de la prueba.

**Barra de progreso:** Ubicada debajo de la información complementaria, esta barra muestra el avance del paciente a lo largo de la prueba, facilitando una percepción visual del progreso alcanzado.

**Sección de botones:** Al final de la interfaz, se incluyen tres botones de control esenciales: uno para iniciar el ejercicio, otro para descargar el archivo de audio generado y un último botón para finalizar la prueba. Esta sección permite una navegación clara y accesible entre las acciones principales del ejercicio.

Estos componentes se incluyen en los ejercicios de fonación como se muestra en la figura 3.19, en los ejercicios de lectura figura 3.20, y los ejercicios de repetición de palabras figura 3.21.




Figura 3.19 Mockup - Interfaz - Ejercicio de fonación.




Figura 3.20 Mockup - Interfaz - Ejercicio de lectura de texto.




Figura 3.21 Mockup - Interfaz - Ejercicio de lectura de texto.

3.3 Desarrollo

3.3.1 Reglas para determinar el pronóstico de la enfermedad de Parkinson

Para determinar los rangos utilizados para la clasificación del pronóstico para la enfermedad de Parkinson se consideran los trabajos de Teixeira *et al.* [48] y Bowen *et al.* [49]. A continuación, se muestran los rangos en la figura 3.22.




Figura 3.22 Rangos para determinar el pronóstico de Parkinson.

### 3.3.2 Módulo de pruebas

Se desarrolló un módulo para el análisis de audio enfocado en el Procesamiento de Lenguaje Natural, este sistema incorpora un análisis semántico avanzado del discurso mediante la transcripción automática de audio utilizando el modelo Whisper de OpenAI, lo que permite convertir las señales de voz en texto de manera precisa, posteriormente, se evalúa la similitud semántica comparando el texto transcrito con un discurso objetivo predefinido, empleando para ello la métrica de `difflib.SequenceMatcher`, este enfoque permite clasificar el nivel de coherencia y relación del discurso, lo que resulta crucial para detectar alteraciones del habla en el contexto de enfermedades neurodegenerativas como la enfermedad de Parkinson, para extraer los valores de las variables shimmer, jitter, y frecuencia fundamental se implementan la biblioteca `librosa` la cual es un paquete de Python para el análisis de música y audio, proporciona los bloques de construcción necesarios para crear sistemas de recuperación de información musical y el uso del marco de trabajo `FastAPI`, a continuación, se muestra la respuesta del módulo en objeto JSON en la figura 3.23.

```
{
  "filename": "muestra_493.wav",
  "texto_transcrito": " Juan se rompió una pierna cuando iba en la moto.",
  "similitud": 0.9583333333333334,
  "clasificacion": "Poco probable",
  "semantic_execution_time": 7.419973611831665,
  "meanF0Hz": 942.315185546875,
  "jitter": 3.4331527590206967,
  "jitter_abs": 0.000036433168133953586,
  "shimmer": 1.7058820724487305,
  "parkinson_prediction": "Positivo",
  "features_execution_time": 0.1287083625793457,
  "execution_time": 7.548681974411011
}
```

Figura 3.23 Respuesta JSON del módulo de pruebas.

### 3.3.3 Implementación de los algoritmos de clasificación

En esta sección se describe el proceso de implementación del modelo de clasificación SVM, seleccionado para este módulo, se utilizó la biblioteca *Scikit-Learn* para configurar, entrenar y

empaquetar el modelo, como resultado de este proceso, se generó un archivo `.joblib` correspondiente al modelo SVM entrenado, para utilizarlo como un proceso preconfigurado.

Este enfoque permite agilizar la implementación del modelo y reducir la complejidad de la configuración del sistema, ya que el modelo de SVM entrenado está empaquetado previamente, eliminando la necesidad de entrenarlo desde cero en cada nuevo entorno.

En el listado 3.1 se muestra el código utilizado para el proceso de entrenamiento y empaquetado del modelo de clasificación SVM.

*Listado 3-1 Código de implementación para el proceso de entrenamiento el modelo de clasificación Support Vector Machine.*

```

1  def train_model(dataset_path):
2      classifier = SVC(kernel="linear", random_state=1)
3      path = dataset_path
4      trainingPath = os.path.sep.join([path, "training"])
5      testingPath = os.path.sep.join([path, "testing"])
6      (trainX, trainY) = load_split(trainingPath)
7      (testX, testY) = load_split(testingPath)
8      le = LabelEncoder()
9      trainY = le.fit_transform(trainY)
10     testY = le.transform(testY)
11     classifier.fit(trainX, trainY)
12     predictions = classifier.predict(testX)
13     cm = confusion_matrix(testY, predictions).ravel()
14     tn, fp, fn, tp = cm
15     accuracy = (tp + tn) / float(cm.sum())
16     sensitivity = tp / float(tp + fn)
17     specificity = tn / float(tn + fp)
18     return classifier, testX, testY, accuracy, sensitivity, specificity

```

Se implementó una arquitectura REST para el servicio RESTful API utilizando el marco de trabajo FastAPI, permitiendo la creación de una interfaz de comunicación estandarizada entre las diversas tecnologías empleadas, este submódulo alberga el modelo SVM empaquetado en un archivo `.joblib`, el cual es accesible a través de una única interfaz que simplifica su uso, se estableció un *endpoint* denominado `"/predict"` de tipo *POST*, que recibe un archivo de audio como entrada para su análisis. El modelo SVM procesa este archivo extrayendo características relevantes de audio, simulando una evaluación para determinar la probabilidad de enfermedad

de Parkinson, el listado 3.2 presenta el código de implementación de este *endpoint* y el uso del modelo SVM para generar las predicciones.

*Listado 3-2 Código de implementación para endpoint POST /predict*

```

1  @app.route('/predict', methods=['POST'])
2  def predict():
3      audio_file = request.files['audio'].read()
4      features = process_audio(audio_file)
5      model = joblib.load('svm_model.joblib')
6      prediction = model.predict_proba([features])
7      result = {
8          'model': 'SVM',
9          'result': {
10             'healthy': prediction[0][0],
11             'parkinson': prediction[0][1]
12         }
13     }
14     return jsonify(result), 200, {'Content-Type': 'application/json'}
```

El flujo de trabajo inicia con el pre procesamiento del archivo de audio recibido como entrada en el cual se extraen características acústicas específicas que sirven para la clasificación, después, el modelo de clasificación SVM utiliza estos parámetros para evaluar la probabilidad de enfermedad de Parkinson en el sujeto evaluado, el proceso concluye con la generación de una respuesta en formato JSON que contiene los valores numéricos obtenidos para cada categoría, proporcionando una interpretación clara y directa del resultado.

La figura 3.22 presenta de forma esquemática el flujo de trabajo diseñado e implementado para el análisis y clasificación del audio en esta investigación.




Figura 3.24 Flujo operacional para la clasificación de ejercicios

### 3.3.4 Implementación del módulo

En esta sección se describe la Interfaz web utilizada por los médicos para acceder a los registros de pruebas realizadas a los pacientes. Al ingresar al sistema, los profesionales seleccionan al paciente de interés y consultar los resultados de las pruebas previas, la figura 3.23 ilustra la ventana de acceso principal al módulo, destacándose principalmente por su función de solicitud de credenciales para ingresar al sistema.




Figura 3.25 Interfaz de inicio de sesión

La Figura 3.24 presenta el panel principal, donde los médicos visualizan información estadística relacionada con los casos analizados. Esta Interfaz incluye datos relevantes como el número de

pruebas realizadas, el porcentaje de probabilidad global del padecimiento, el historial de resultados clasificados por género.



Figura 3.26 Panel principal.

En la figura 3.25 se muestra la interfaz de ejercicios realizados donde se visualizan los ejercicios realizados por el paciente para su análisis y cálculo del pronóstico.




Figura 3.27 Interfaz de ejercicios realizados.

En la Figura 3.26, se muestra el panel estadístico centrado en el historial de pruebas de cada paciente. Los controles permiten consultar los resultados anteriores, el seguimiento de los resultados globales del paciente y el análisis detallado de la evolución del estado del paciente a lo largo del tiempo.




Figura 3.28 Interfaz de historial del paciente

En la Figura 3.27 se visualizan los detalles de los ejercicios de la prueba, donde los médicos consultan en detalle los resultados de cada prueba realizada, visualizando datos como el nivel de precisión obtenido, el tiempo de ejecución y otros parámetros relevantes.




Figura 3.29 Interfaz de los detalles de los ejercicios de la prueba.

La Figura 3.28 muestra el catálogo de ejercicios de voz, el cual permite seleccionar el tipo de ejercicio a realizar por parte del paciente.



Figura 3.30 Interfaz de catálogo de ejercicios de voz.

La Figura 3.29 presenta el menú de selección de vocal, el cual permite elegir un ejercicio de fonación correspondiente a la vocal seleccionada.




Figura 3.31 Interfaz del menú de selección de vocal.

La Figura 3.30 muestra la Interfaz del ejercicio de fonación de la vocal a, que permite la persistencia del audio para su posterior procesamiento y la obtención del pronóstico correspondiente.

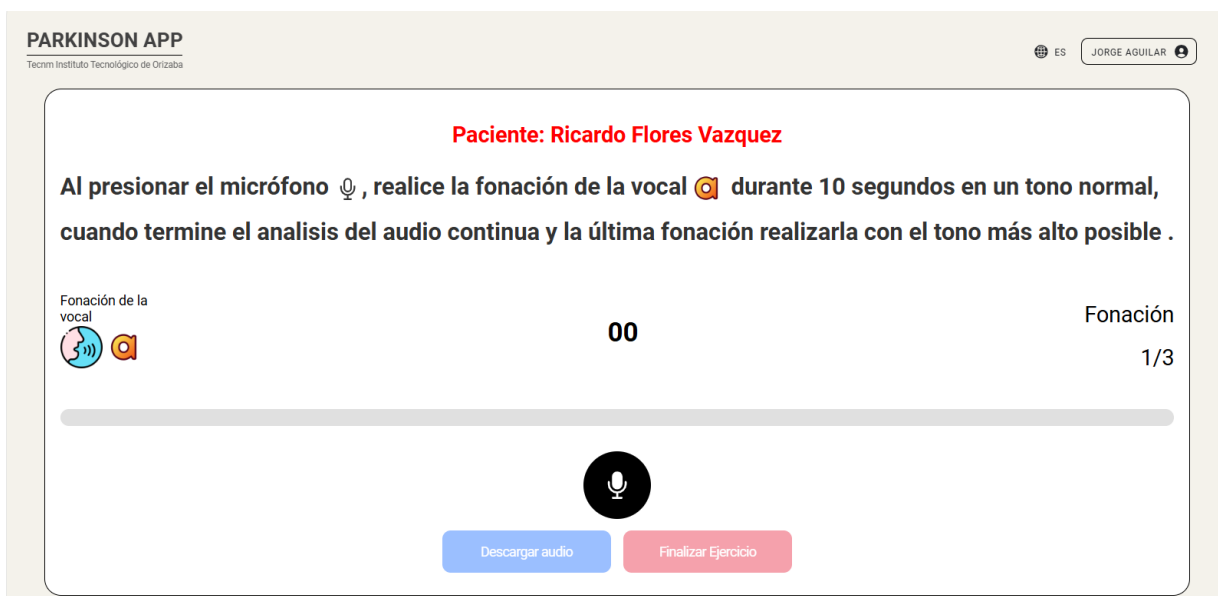



Figura 3.32 Interfaz del ejercicio de fonación de la vocal a.

La Figura 3.31 presenta el menú de selección de lectura, que permite elegir un ejercicio correspondiente al número de lectura seleccionado.



*Figura 3.33 Interfaz del menú de selección de lectura.*

La Figura 3.32 muestra la Interfaz del ejercicio de lectura 1, que muestra un texto para realizar su lectura y permite almacenar el audio de la lectura para su posterior procesamiento y la obtención del pronóstico correspondiente




Figura 3.34 Interfaz del ejercicio de lectura 1.

La Figura 3.33 muestra la Interfaz del ejercicio de repetición de palabras, que permite registrar la repetición de 25 palabras y almacenar el audio para su posterior procesamiento y la obtención del pronóstico correspondiente.



Figura 3.35 Interfaz del ejercicio de repetición de palabras.

## Capítulo 4. Resultados

En este capítulo se presentan los casos de estudio realizados para validar la solución propuesta en el sistema de análisis de fonación de vocales, lectura de textos y repetición de palabras aplicado a la enfermedad de Parkinson. Se analizó el desempeño del módulo web y del componente de clasificación basado en técnicas de análisis de patrones acústicos. A continuación, se describen los resultados obtenidos.

### 4.1 Casos de estudio: Detección temprana de la Enfermedad de Parkinson

Se realizó un estudio práctico para evaluar la efectividad del sistema en la identificación temprana de síntomas de la enfermedad de Parkinson. El objetivo fue verificar la precisión del análisis de fonación de vocales, lecturas de texto y repetición de palabras, utilizando las recomendaciones médicas de expertos en neurología.

El estudio se llevó a cabo con tres pacientes, clínicamente evaluados por especialistas médicos. Los pacientes interactuaron con el sistema web y participaron en las pruebas de fonación a lo largo de dos meses, desde el 4 septiembre de 2024 hasta el 4 de noviembre de 2024. Cada paciente se registró en el sistema y realizó diversas pruebas de fonación diseñadas para detectar patrones asociados a la enfermedad de Parkinson.

#### 4.1.1 Caso de estudio 1: Paciente con pronóstico poco probable

Este paciente, un hombre de 56 años, muestra síntomas iniciales de la enfermedad de Parkinson, aunque su diagnóstico clínico confirmado como negativo, se le realizaron pruebas periódicas de fonación utilizando una laptop ThinkPad y el módulo web. En la prueba más reciente, se obtuvo un tiempo de 10 segundos para el cálculo del pronóstico y se registraron resultados acústicos con un jitter de 0.03, shimmer de 0.33 y una frecuencia fundamental ( $f_0$ ) de 1.30. La evaluación arrojó un pronóstico poco probable, indicando una baja probabilidad de Parkinson, con una precisión diagnóstica de 93.55%.

#### **4.1.2 Caso de estudio 2: Paciente con pronóstico altamente probable**

El segundo paciente, una mujer de 51 años, no presentaba inicialmente síntomas claros de Parkinson, aunque sus antecedentes médicos indicaban un riesgo potencial de desarrollarlo. En una evaluación reciente, con una duración de 10 segundos, los resultados mostraron un jitter de 0.10, shimmer de 0.70 y una frecuencia fundamental ( $f_0$ ) de 2.30. Estos valores, junto con el resultado general de la prueba, indicaron un pronóstico de "altamente probable" con una precisión de 89.00%, lo cual sugiere una probabilidad elevada de la enfermedad.

#### **4.1.3 Caso de estudio 3: Paciente con pronóstico probable**

Este paciente, un hombre de 54 años, no presentaba síntomas evidentes de Parkinson, y los estudios clínicos previos indicaron un diagnóstico negativo, sin embargo, fue incluido en el estudio para monitorear su evolución de salud mediante pruebas de fonación, en la evaluación reciente, con un ejercicio que tomo en calcular 17 segundos y obtuvo, los valores de jitter (0.30), shimmer (0.36) y una frecuencia fundamental ( $f_0$ ) de 1.10 indicaron un pronóstico "probable" de la enfermedad, con una precisión de 93.55% y un semáforo en amarillo, sugiriendo precaución en el seguimiento.

#### **4.1.4 Datos iniciales**

Durante el estudio, los pacientes realizaron pruebas de fonación de vocales, lecturas de texto y repetición de palabras, de manera regular, apoyados por profesionales médicos que supervisaron los resultados, las pruebas se centraron en la captura de señales acústicas, permitiendo al sistema identificar posibles patrones de deterioro relacionados con la enfermedad de Parkinson.

Cada paciente participó en pruebas semanales durante el periodo de evaluación, esto permitió al sistema generar datos consistentes que utilizados para ajustar el clasificador automático.

#### **4.1.5 Clasificación automática de datos**

Con base en los resultados estadísticos obtenidos por el componente de clasificación de la enfermedad de Parkinson, se aplicaron las reglas predefinidas en conjunto con los valores asociados en la Tabla 4.1.

*Tabla 4.1 Valores de referencia para la identificación de Parkinson.*

| Tipo de dato | Rango       | Resultado          | Descripción                                                      |
|--------------|-------------|--------------------|------------------------------------------------------------------|
| Numérico     | 0.00 – 0.40 | Poco Probable      | Los resultados demostraron una baja probabilidad de padecimiento |
| Numérico     | 0.41 – 0.80 | Probable           | Los resultados demostraron probabilidad de padecimiento          |
| Numérico     | 0.81 – 1.00 | Altamente probable | Los resultados demostraron una alta probabilidad de padecimiento |

#### 4.1.6 Resultados

El módulo permite realizar las pruebas de fonación de vocales, lecturas de texto y repetición de palabras, donde los pacientes realizan ejercicios específicos para que el sistema capture y analice sus características acústicas, en la figura 4.1 se presenta catálogo de selección de los ejercicios (fonación, lectura y repetición).



*Figura 4.1 Selección del tipo de ejercicio.*

En las figuras 4.2, 4.3 y 4.4 se ilustran los ejercicios iniciales y su ejecución por parte de uno de los pacientes. Al finalizar, los resultados se almacenan para su consulta desde el historial de ejercicios.




Figura 4.2 Módulo web - Aplicación del ejercicio de fonación de vocal.




Figura 4.3 Módulo web - Aplicación del ejercicio de lecturas de texto.



Figura 4.4 Módulo web - Aplicación del ejercicio de repetición de palabras.

Una vez realizado el ejercicio de voz, se consulta en la Interfaz de pacientes desde el botón de ver ejercicios, en la figura 4.5 se muestra la interfaz de pacientes.




Figura 4.5 Interfaz pacientes

Para realizar en pronóstico de los audios, el usuario desde la Interfaz historial de ejercicios se selecciona el botón “realizar pronostico”, que habilita un modal que permite la selección de ejercicios para realizar el cálculo del pronóstico de los ejercicios correspondientes. En la figura 4.6 se muestra el historial de ejercicios realizados por un paciente.

**Parkinson App**

Nueva prueba de Parkinson +

Variables ^v

Inicio

Pacientes

Registro

Salir

**Ejercicios realizados**

ES Jorge Aguilar

**Carlos Platas Meneses**  
TecNM Instituto Tecnológico de Orizaba  
56 años

**Ejercicios totales**  
4

**REALIZAR PRONÓSTICO**

**Ejercicios realizados**

| ID  | Ejercicio              | Precisión | Tiempo | Resultado     | Muestra   | Jitter | Shimmer | vF0  |
|-----|------------------------|-----------|--------|---------------|-----------|--------|---------|------|
| 420 | Fonacion vocal /a/     |           | 10s    | Sin resultado | DESCARGAR | 0.00   | 0.00    | 0.00 |
| 421 | Fonacion vocal /e/     |           | 10s    | Sin resultado | DESCARGAR | 0.00   | 0.00    | 0.00 |
| 422 | Lectura 1              |           | 10s    | Sin resultado | DESCARGAR | 0.00   | 0.00    | 0.00 |
| 423 | Repeticion de palabras |           | 10s    | Sin resultado | DESCARGAR | 0.00   | 0.00    | 0.00 |

ANTERIOR Página 1 de 1 SIGUIENTE

Figura 4.6 Interfaz del historial de ejercicios.

En la figura 4.7 se muestra el modal que permite seleccionar los ejercicios para realizar su pronóstico.




Figura 4.7 Interfaz del modal para la selección de ejercicios.

En la figura 4.8 se muestra el resultado del pronóstico calculado para los ejercicios seleccionados.




Figura 4.8 Interfaz del resultado de pronóstico.

En la figura 4.9 se muestra la interfaz donde se presentan los detalles de los ejercicios del pronóstico.




Figura 4.9 Interfaz de los detalles de los ejercicios del pronóstico.

Este enfoque permite realizar una clasificación eficaz de los síntomas de enfermedad de Parkinson mediante el análisis de fonación de vocales, lecturas de texto y repetición de palabras proporcionando una herramienta complementaria para los médicos en la toma de decisiones. Sin embargo, los resultados obtenidos por el sistema no constituyen un diagnóstico definitivo, sino que tienen que ser interpretados por especialistas en el contexto de la evaluación médica completa.

Los resultados muestran la utilidad del sistema para detectar patrones tempranos de enfermedad de Parkinson, contribuyendo a una atención más personalizada y eficiente para los pacientes.

## Capítulo 5. Conclusiones

Se logró implementar el módulo para la detección temprana de la enfermedad de Parkinson, de forma inicial se planteó desarrollarlo con el uso de la caja de herramientas KerasNLP, aunque la falta de funciones para el proceso de detección de la enfermedad de Parkinson hizo que se replanteara la idea y se decidió utilizar librosa para la extracción de variables utilizadas en el análisis de audio.

Se destaca el uso de la utilización de técnicas de Procesamiento de Lenguaje Natural permite obtener resultados de mayor precisión y eficacia en comparación de los algoritmos analizados en este trabajo.

Se desarrolló el módulo de software para la detección temprana de la enfermedad de Parkinson, mediante técnicas de Procesamiento de Lenguaje Natural (PLN) , el módulo se integra por 3 tipos de ejercicios fonación de las vocales, lecturas de textos y repetición de palabras enfocados al pronóstico de la enfermedad de Parkinson a través de la voz, las pruebas de validación, retroalimentación y evaluación realizadas dieron a conocer que la interacción a través de su uso es fácil de aprender , aunque el diseño en algunos ejercicios es poco pequeño, lo que genera dificultad al leer las palabras del ejercicio repetición de palabras.

Finalmente, la integración del módulo del pronóstico de la enfermedad de Parkinson no está limitado a la enfermedad de Parkinson, es posible utilizarlo de tal forma que reconozca enfermedades relacionadas con impedimentos de la voz, aunque previamente deba entrenarse un nuevo modelo.

### 5.1 Recomendaciones

En cuanto a trabajo a futuro, se sugiere:

1. **Ampliar la capacidad del modelo:** Se recomienda mejorar el rendimiento y precisión del modelo, permitiendo estudios de clasificación más detallados. Esto podría incluir la

integración de nuevos sistemas de información, como la supervisión de la actividad motriz del paciente, lo cual aportaría una visión más integral de su estado físico y neurológico.

2. **Probar nuevos modelos de clasificación:** Se sugiere explorar y comparar diferentes modelos de clasificación (e.g., redes neuronales, árboles de decisión, modelos basados en vecinos cercanos) para evaluar su rendimiento y precisión en la detección de patrones relacionados con la enfermedad de Parkinson y otras condiciones neurológicas.
3. **Perfeccionar el modelo de procesamiento de voz:** Continuar optimizando el modelo actual y explorar metodologías para integrar datos biomédicos adicionales, lo que contribuirá a un diagnóstico más robusto.

## Productos académicos

En esta sección se muestran los productos académicos que se han realizado.

### 6.1 Artículo de congreso

Análisis comparativo de técnicas de aprendizaje automático para la detección de la enfermedad de Parkinson mediante el reconocimiento de voz



**Autores:** Justo Francisco León Pastor Baak, Giner Alor Hernández, Nancy Aracely Cruz Ramos, José Luis Sánchez Cervantes, Lisbeth Rodríguez Mazahua

**Palabras clave:** Bagged SVM, Enfermedad de Parkinson, Procesamiento de Lenguaje Natural, Random Forest, Reconocimiento de voz.

**Presentado en:** XVI Congreso Mexicano de Inteligencia Artificial, COMIA 2024

### 6.1.1 PDF publicación del artículo

ISSN 1870-4069

## **Análisis comparativo de técnicas de aprendizaje automático para la detección de la enfermedad de Parkinson mediante el reconocimiento de voz**

Justo Francisco León Pastor Baak, Giner Alor Hernández,  
Nancy Aracely Cruz-Ramos, José Luis Sánchez Cervantes,  
Lisbeth Rodríguez Mazahua

Tecnológico Nacional de México, Instituto Tecnológico de Orizaba,  
División de Estudios de Posgrado e Investigación,  
México

{M22011021, giner.ah, jose.sc.dci,  
lisbeth.rm}@orizaba.tecnm.mx, ncruz@ito-depi.edu.mx

**Resumen.** La enfermedad de Parkinson es una de las enfermedades neurodegenerativas más prevalentes a nivel mundial siendo aproximadamente el 1% en mayores de 60 años; su progresión es gradual y sin cura conocida. En este trabajo se presenta un análisis comparativo de los algoritmos de inteligencia artificial usados para la detección temprana de la enfermedad de Parkinson mediante el reconocimiento de voz. Para este análisis se consideraron 5 conjuntos de datos y 11 algoritmos de aprendizaje automático. Como resultado de este análisis, se obtuvo que los algoritmos Bagged SVM, Random Forest y Gradient Boosting presentaron los mejores resultados en sensibilidad, siendo aplicados en el conjunto de datos Parkinson's Disease Classification.

**Palabras claves:** Bagged SVM, enfermedad de Parkinson, procesamiento de lenguaje natural, random forest, reconocimiento de voz.

## **Comparative Analysis of Machine Learning Techniques for Detecting Parkinson's Disease Using Speech Recognition**

**Abstract.** Parkinson's disease is one of the most prevalent neurodegenerative diseases worldwide being approximately 1% in people over 60 years old; its progression is gradual and without known cure. This paper presents a comparative analysis of artificial intelligence algorithms used for early detection of Parkinson's disease using speech recognition. For this analysis, 5 datasets and 11 machine learning algorithms were considered. As a result, Bagged SVM, Random Forest and Gradient Boosting algorithms presented the best results in recall, being applied to the Parkinson's Disease Classification dataset.

**Keywords:** Bagged SVM, natural language processing, Parkinson's disease, random forest, speech recognition.

## 6.2 Retribución social



La RED Nacional de Actividades Juveniles en Ciencia y Tecnología (RED), la Universidad Popular Autónoma del Estado de Puebla (UPAEP), el Movimiento Internacional para el Recreo Científico y Técnico de América Latina (MILSET AMLAT), el Colegio Americano de Xalapa a través de la Universidad Tecnológica del Centro de Veracruz

OTORGAN LA PRESENTE CONSTANCIA A:

**Justo Francisco León Pastor Baak**


Por su destacada participación como MENTOR en el Hackathon de ExpoCiencias Veracruz Regional Cuitláhuac 2024, realizada los días 23 y 24 de mayo en las instalaciones de la Universidad Tecnológica del Centro de Veracruz.

**LMKT. Víctor Hernández Melgarejo**  
Coordinador Estatal – RED Nacional de  
Actividad es Juveniles en Ciencia y  
Tecnología

**Mtro. Juan Manuel Arzola Castro**  
Rector – Universidad Tecnológica del Centro  
de Veracruz



## 6.3 Poster y video



**Desarrollo de un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de Procesamiento de Lenguaje Natural**

Justo Francisco León Pastor Baak, Giner Alor Hernández, Nancy Aracely Cruz Ramos, José Luis Sánchez Cervantes, Lisbeth Rodríguez Mazahua

Maestría en Sistemas Computacionales

### INTRODUCCIÓN

La Organización Mundial de la Salud reporta un aumento sostenido en los casos de Parkinson, afectando a más de 8.5 millones de personas en 2019 y con 329,000 muertes estimadas en 2020. En México, la incidencia ha crecido significativamente, de 6.7 en 2014 a 14.9 por cada 100,000 habitantes en 2023. La enfermedad de Parkinson, la segunda enfermedad neurodegenerativa más común tras el Alzheimer, impacta principalmente a adultos mayores y se manifiesta con desórdenes motores y alteraciones en el lenguaje, entre otros síntomas.

### OBJETIVO

Desarrollar un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de procesamiento de lenguaje natural.

### RESULTADO

La aplicación "Parkinson App" se desarrolló para realizar el pronóstico sobre la enfermedad de Parkinson mediante técnicas de Procesamiento de Lenguaje Natural. Esta innovadora herramienta permite que el usuario realice ejercicios de fonación y lectura, presentándole una serie de textos que debe leer en voz alta. A partir de estas grabaciones, la aplicación utiliza procesos avanzados de inteligencia artificial para evaluar las características de la voz y realizar una evaluación detallada para obtener un pronóstico sobre la enfermedad de Parkinson.



Figura 1 Arquitectura del módulo web para la detección temprana de la enfermedad de Parkinson mediante técnicas de Procesamiento de Lenguaje Natural.

La figura 1 muestra las capas del módulo web que mediante tecnologías como Angular, PHP, el marco de trabajo Ionic Framework y el sistema de base de datos MySQL permitan la recolección de datos del usuario, para extraer características

de audios utilizando un técnicas de Inteligencia Artificial y el uso de la voz, en la figura 2, 3 y 4 muestran las interfaces del módulo desarrollado.



Figura 2 Pantalla del ejercicio de fonación de vocal.




Figura 3 Pantalla de los ejercicios realizados y su pronóstico.



Figura 4 Submódulo para la extracción y análisis de características del audio.

### CONCLUSIONES

En este trabajo se presentó el artículo con título "Análisis comparativo de técnicas de aprendizaje automático para la detección de la enfermedad de Parkinson mediante el reconocimiento de voz", este trabajo se elaboró en colaboración de:

Justo Francisco León Pastor Baak, Giner Alor Hernández, Nancy Aracely Cruz Ramos, José Luis Sánchez Cervantes, Lisbeth Rodríguez Mazahua.





# EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA

## DIVISIÓN DE ESTUDIO DE POSGRADO E INVESTIGACIÓN

### Maestría en Sistemas Computacionales

### Desarrollo de un módulo de software para la detección temprana de la enfermedad de Parkinson mediante técnicas de Procesamiento de Lenguaje Natural

**Presenta**

I.S.C. Justo Francisco  
León Pastor Baak

**Director**

Dr. Giner Alor Hernadez

**Codirector**

M.S.C. Nancy Aracely  
Cruz Ramos

g) Video\_tesis - Jleomp

## Bibliografía

- [1] Cummings, L. Jeffrey, Pillai y Jagan, *Neurodegenerative diseases unifying principles*, United States of America: Oxford University Press, 2017. p 1.
- [2] W. G. Bradley y G. Walter, *Neurology in clinical practice*, Philadelphia: Butterworth-Heinemann, 2004. pp 3-4.
- [3] R. Martínez-Fernández, C. G.-S. C, Á. Sánchez-Ferro, and J. Á. Obeso, "ACTUALIZACIÓN EN LA ENFERMEDAD DE PARKINSON," *Revista Médica Clínica Las Condes*, vol. 27, no. 3, pp. 363–379, May 2016, doi: 10.1016/j.rmcl.2016.06.010
- [4] J. Jankovic, "Parkinson's disease: clinical features and diagnosis," *Journal of Neurology Neurosurgery & Psychiatry*, vol. 79, no. 4, pp. 368–376, Mar. 2008, doi: 10.1136/jnnp.2007.131045
- [5] L. Rouhiainen, *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*, España: Alienta, 2018, p. 17.
- [6] S. J. Russell, J. Stuart y P. A. Norvig, *Artificial intelligence : a modern approach*, 3<sup>rd</sup> ed. Prentice Hall, 2016, p. 861 .
- [7] H. L. Cole, H. Hannes y M. Hapke, *Natural Language Processing IN ACTION Understanding, analazing, and generating text whit Python*, SHELTER ISLAND: MANNING , 2019 .
- [8] S. Bird, E. Klein y E. Loper, *Natural Language Processing with Python*, 1 ed., Sebastopol: O'Reilly Media, 2009.
- [9] D. Jurafsky y J. Martin, *Speech and Language Processing*, New Jersey: Prentice Hall, 2008, pp. 230-241.
- [10] A. Tsanas and M. Little. "Parkinsons Telemonitoring," UCI Machine Learning Repository, 2009. [En línea]. Disponible en: <https://doi.org/10.24432/C5ZS3N>

- [11] M. Little, P. McSharry, E. Hunter y L. Raming, "Suitability of dysphonia measurements for telemonitoring of Parkinson's", *IEEE Transactions on Biomedical Engineering*, vol. 56, n° 4, pp. 1015-1022, 2009, doi: 10.1109/TBME.2008.2005954
- [12] M. Little, P. McSharry, S. Roberts, D. Costello y I. Moroz, "Exploiting Nonlinear Recurrence and Fractal Scaling Properties for Voice", *BioMedical Engineering OnLine*, pp. 6-23, 2007, doi: 10.1038/npre.2007.326.1
- [14] L. Naranjo, C. Pérez y J. Martín, "Addressing voice recording replications for tracking Parkinson's disease progression", *Med Biol Eng Comput*, vol. 55, n° 3, pp. 365-373, 2017, doi: 10.1007/s11517-016-1512-y
- [15] J. Hlavnicka, T. Tykalov, K. Onka, E. Rika, J. Ruzs y J. J., "Early biomarkers of Parkinson's disease based on natural connected speech", UCI Machine Learning Repository. 2017.[En línea] Disponible en: <https://doi.org/10.24432/C5W02Q>
- [16] O. Kursun, B. Sakar, M. Isenkul, C. Sakar, A. Sertbas y F. Gurgen, "Parkinson Speech Dataset with Multiple Types of Sound Recordings", UCI Machine Learning Repository. 2014. [En línea] Disponible en: <https://doi.org/10.24432/C5NC8M>
- [17] B. E. Sakar, M. E. Isenkul, C. O. Sakar, A. Sertbas, F. Gurgen, S. Delil, H. Apaydin y O. Kursun, "A comparative analysis of speech signal processing algorithms for Parkinson's disease classification and the use of the tunable Q-factor wavelet transform", *IEEE J Biomed Health Inform*, vol. 74, pp. 255-263, 2019, <https://doi.org/10.1016/j.asoc.2018.10.022>
- [18] C. Sakar, G. Serbes, A. Gunduz, H. Nizam y B. Sakar, "Parkinson's Disease Classification", UCI Machine Learning Repository. 2018. Disponible en: <https://doi.org/10.24432/C5MS4X>
- [19] Enfermedad de Parkinson. <https://www.who.int/es/news-room/fact-sheets/detail/parkinson-disease>, last accessed 2024/03/30.
- [20] Martínez, D., Rodríguez, M., Velázquez, E. S., Cervantes, A., González, A., Corona, T., Velásquez, L.: Incidencia y distribución geográfica de la enfermedad de Parkinson en Méxi-co. *Salud Publica Mex* 62, 873–875, (2020).

- [21] Leung, I.H.K., Strudwick, M.W. A systematic review of the challenges, emerging solutions and applications, and future directions of PET/MRI in Parkinson's disease. *EJNMMI Rep.* **8**, 3 (2024). <https://doi.org/10.1186/s41824-024-00194-9>
- [22] Horstink M, Tolosa E, Bonuccelli U, et al. Review of the therapeutic management of Parkinson's disease. Report of a joint task force of the European Federation of Neurological Societies and the Movement Disorder Society-European section. Part I: early (uncomplicated) Parkinson's disease. *Eur J Neurol* 2006; **13**(11): 1170–1185. <https://doi.org/10.1002/mds.29066>
- [23] León-Cabrera, P., Pagonabarraga, J., Morís, J., Martínez-Horta, S., Marín-Lahoz, J., Horta-Barba, A., Bejr-Kasem, H., Kulisevsky, J., & Rodríguez-Fornells, A. . "Neural signatures of predictive language processing in Parkinson's disease with and without mild cognitive impairment". *Cortex*, 2021 ,141, pp. 112–127, <https://doi.org/10.1016/j.cortex.2021.03.032>
- [24] Orozco-Arroyave, J. R., Vásquez-Correa, J. C., Vargas-Bonilla, J. F., Arora, R., Dehak, N., Nidadavolu, P. S., Christensen, H., Rudzicz, F., Yancheva, M., Chinaei, H., Vann, A., Vogler, N., Bocklet, T., Cernak, M., Hannink, J., & Nöth, E., “NeuroSpeech: An open-source software for Parkinson's speech análisis”, *Digital Signal Processing: A Review Journal*, 2018, 77, 207–221, doi: 10.1016/j.dsp.2017.07.004.
- [25] Hyder, R., Jensen, M., Højlund, A., Kimppa, L., Bailey, C. J., Schaldemose, J. L., Kinnerup, M. B., Østergaard, K., & Shtyrov, Y. "Functional connectivity of spoken language processing in early-stage Parkinson's disease: An MEG study". *NeuroImage: Clinical*, 32, 2021, doi: 10.1016/j.nicl.2021.102718.
- [26] Mostafa, S. A., Mustapha, A., Khaleefah, S. H., Ahmad, M. S., & Mohammed, M. A., “Evaluating the performance of three classification methods in diagnosis of parkinson's Disease”, *Advances in Intelligent Systems and Computing*, 2018, 700, pp. 43–52, doi: 10.1007/978-3-319-72550-5\_5.
- [27] Duncan, S., “PRELIMINARY DATA ON EFFECTS OF BEHAVIORAL AND LEVODOPA THERAPIES ON SPEECH-ACCOMPANYING GESTURE IN

- PARKINSON’S DISEASE”, International Conference on Spoken Language Processing, 2002, 7th, doi: 10.21437/ICSLP.2002-646
- [28] Jiang, H., Lim, W. Y. B., Ng, J. S., Wang, Y., Chi, Y., & Miao, C., “Towards Parkinson’s disease prognosis using self-supervised learning and anomaly detection. ICASSP”, *IEEE International Conference on Acoustics, Speech and Signal Processing – Proceedings*, 2021-June, 3960–3964, doi: 10.1109/ICASSP39728.2021.9414840.
- [29] Locke, S., Bashall, A., Al-Adely, S., Moore, J., Wilson, A., & Kitchen, G. B., “Natural language processing in medicine: A review”, In *Trends in Anaesthesia and Critical Care*, 2021, 38, pp. 4–9, doi: 10.1016/j.tacc.2021.02.007.
- [30] Miller, N., “Communication changes in Parkinson’s disease”. In *Practical Neurology*, 2017, 17(4), pp. 266–274, doi: 10.1136/practneurol-2017-001635.
- [31] Novotný, M., Ruz, J., Čmejla, R., & Růžicka, E., “Automatic evaluation of articulatory disorders in Parkinson’s Disease”, *IEEE Transactions on Audio, Speech and Language Processing*, 2014, 22(9), pp. 1366–1378, doi: 10.1109/TASLP.2014.2329734.
- [32] Mollaei, F., Shiller, D. M., Baum, S. R., & Gracco, V. L., “Early auditory responses to speech sounds in Parkinson’s disease: preliminary data”, *Scientific Reports*, 2022, 12(1), doi: 10.1038/s41598-022-05128-8.
- [33] Lonini, L., Dai, A., Shawen, N., Simuni, T., Poon, C., Shimanovich, L., Daeschler, M., Ghaffari, R., Rogers, J. A., & Jayaraman, A., “Wearable sensors for Parkinson’s disease: which data are worth collecting for training symptom detection models”, *Npj Digital Medicine*, 2018, 1(1), doi: 10.1038/s41746-018-0071-z.
- [34] Murray, G., Jessiman, L., & McKenzie B., “Language-Based Automatic Assessment of Cognitive and Communicative Functions Related to Parkinson’s Disease”, *Proceedings of the First International Workshop on Language Cognition and Computational Models*, pages 63–74, pp. 63-74, 2018, [aclanthology.org/W18-4107](https://aclanthology.org/W18-4107)
- [35] Chronowski, M., Klaczynski, M., Dec-Cwiek, M., & Porebska, K., “Parkinson’s disease diagnostics using AI and natural language knowledge transfer”, *arXiv preprint arXiv:2204.12559*. 2022, <https://doi.org/10.48550/arXiv.2204.12559>

- [36] Pappagari, R., Cho, J., Moro-Velazquez, L., & Dehak, N., “Using state of the art speaker recognition and natural language processing technologies to detect Alzheimer’s disease and assess its severity”, *Proceedings of the Annual Conference of the International Speech Communication Association*, INTERSPEECH, 2020-October, pp. 2177–2181, doi: 10.21437/Interspeech.2020-2587.
- [37] Nogales, A., Garcia-Tejedor, A. J., Maitin, A. M., Perez-Morales, A., Castillo, M. D. del, & Romero, J. P., “BERT Learns from Electroencephalograms about Parkinson’s Disease: Transformer-Based Models for Aid Diagnosis”, *IEEE Access*, 2022, 10, pp. 101672–101682, doi: 10.1109/ACCESS.2022.3201843.
- [38] Chakraborty, S., Aich, S., Jong-Seong-Sim, Han, Eunyoung., Park, J., Kim H., “Parkinson’s Disease Detection from Spiral and Wave Drawings using Convolutional Neural Networks: A multistage Classifier Approach”, *The 22nd International Conference on Advanced Communications Technology*, 2020, pp. 298-303, doi: 10.23919/ICACT48636.2020.9061497.
- [39] Frid, A., Hazan, H., Hilu, D., Manevitz, L., Ramig, L. O., & Sapir, S., “Computational diagnosis of Parkinson’s disease directly from natural speech using machine learning techniques. Proceedings”, *IEEE International Conference on Software Science, Technology and Engineering*, 2014, pp. 50–53, doi: 10.1109/SWSTE.2014.17.
- [40] Nissar, I., Rizvi, D. R., Masood, S., & Mir, A. N., “Voice-based detection of parkinson’s disease through ensemble machine learning approach: A performance study”, *EAI Endorsed Transactions on Pervasive Health and Technology*, 2019, 5(19). doi: 10.4108/eai.13-7-2018.162806.
- [41] Microsoft, “Visual Studio Code Documentation,” 2024. <https://code.visualstudio.com/docs> (accesado Sep. 09, 2024)
- [42] Docker, “Docker Documentarion,” 2024. <https://docs.docker.com/> (accesado Sep. 09, 2024).

- [43] TypeScript Community, “The TypeScript Handbook,” *TypeScript*, Abr. 11, 2024. <https://www.typescriptlang.org/docs/handbook/intro.html> (accesado Sep. 17, 2024).
- [44] Angular Community, “Angular Docs,” Angular, 2024. <https://angular.io/docs> (accesado Sep. 02, 2024).
- [45] C. Griffith, *Mobile App Development with Ionic*, Revised Edition: Cross-Platform Apps with Ionic, Angular, and Cordova. O’Reilly Media, 2017.
- [46] The PHP Group, “PHP Official Documentation,” 2024, <https://www.php.net/docs.php> (accesado Sep. 01, 2024).
- [47] S. Ramírez, *FastAPI*, <https://fastapi.tiangolo.com>, (accesado Sep. 09, 2024)
- [48] Pedregosa et al., “*Scikit-Learn: Machine Learning in Python*,” J. Mach. Learn. Res., vol. 12, pp. 2825–2830, Nov. 2011.
- [49] Oracle, “What is MySQL?,” 2024, <https://dev.mysql.com/doc/refman/8.0/en/what-is-mysql.html> (accesado Sep. 30, 2024)
- [50] Teixeira, C Oliveira, C Lopes, Vocal Acoustic Analysis - Jitter, Shimmer and HNR Parameters , Procedia Technology, vol 9 20213 , pp 1112-1122, doi: 10.1016/j.protcy.2013.12.124
- [51] Bowen LK, Hands GL, Pradhan S, Stepp CE. Effects of Parkinson's Disease on Fundamental Frequency Variability in Running Speech. J Med Speech Lang Pathol. 2013 Sep;21(3):235-244.
- [52] Parkinson’s Disease Data Set, <https://www.kaggle.com/datasets/vikasukani/parkinsons-disease-data-set>, accessed 2024/03/30.
- [53] Vapnik, The Nature of Statical Learning Theory, Second Edition , Springer p.38
- [54] Shi et Al, Mobile Edge Artificial Intelligence: Opportunities and Challenges, 1st Edition, ELSEVIER, 2022
- [55] Mitchel, Machine Learning, MacGraw-Hill Science, Marzo 1 1997.

- [56] Jurafsky and Martin, *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models*, 3<sup>ra</sup> , 2024
- [57] Rahman W, Lee S, Islam MS, Antony VN, Ratnu H, Ali MR, Mamun AA, Wagner E, Jensen-Roberts S, Waddell E, Myers T, Pawlik M, Soto J, Coffey M, Sarkar A, Schneider R, Tarolli C, Lizarraga K, Adams J, Little MA, Dorsey ER, Hoque E., “Detecting Parkinson Disease Using a Web-Based Speech Task: Observational Study”, *J Med Internet Res*, 2021, 23(10). doi: 10.2196/26305.
- [58] Tsanas A, Little MA, McSharry PE, Ramig LO., "Nonlinear speech analysis algorithms mapped to a standard metric achieve clinically useful quantification of average Parkinson's disease symptom severity", *J R Soc Interface*, 2011 Jun 6;8(59):842-55. doi: 10.1098/rsif.2010.0456
- [59] Orozco, Juan Rafael & Arias-Londoño, Julian D. & Vargas-Bonilla, J. & González-Rátiva, María & Noeth, Elmar. "New Spanish speech corpus database for the analysis of people suffering from Parkinson’s disease", 2014. *Proceedings of the 9th Language Resources and Evaluation Conference (LREC)*, 342-347.