

# Clasificación del grado de afectación de Parkinson usando la señal de vibración de pacientes diagnosticados con la enfermedad de Parkinson

Classification of the degree of involvement of Parkinson's using the vibration signal of patients diagnosed with Parkinson's disease

Eduardo Ibarra-Sánchez<sup>1</sup> , Juan Francisco Mosiño<sup>1\*</sup> , Raúl Santiago-Montero <sup>1</sup>, María del Rosario Baltazar- Flores<sup>1</sup>, Emmanuel Martínez-Hernández<sup>1</sup>

<sup>1</sup> U Tecnológico Nacional de México/Instituto Tecnológico de León.  
Av. Tecnológico S/N - Fracc. Industrial Julián de Obregón. León Guanajuato - C.P. 37290  
Correo-e: jfmosino@gmail.com

## PALABRAS CLAVE:

Enfermedad de Parkinson, señales digitales, algoritmos de clasificación, filtrado de señales.

## RESUMEN

En este artículo se presenta un estudio de la clasificación del grado de afectación en pacientes diagnosticados con la enfermedad de Parkinson. La captura de las señales de vibración de vibración se realiza usando un acelerómetro de una pulsera bluetooth. El procesamiento de las señales de vibración se realiza procesando el valor rms y valores pico de las señales de los pacientes. Finalmente se utilizan diferentes clasificadores para evaluar el grado de afectación de la vibración en pacientes con Parkinson.

## KEYWORDS:

Parkinson's disease, digital signals, classification algorithms, signal filtering.

## ABSTRACT

This article presents a study of the classification of the degree of involvement in patients diagnosed with Parkinson's disease. The vibration signals are captured using an accelerometer from a bluetooth bracelet. The processing of the vibration signals is done by processing the rms value and peak values of the patient signals. Finally, different classifiers are used to assess the degree of vibration involvement in Parkinson's patients.



## 1 INTRODUCCIÓN

Las enfermedades neurodegenerativas se caracterizan por la pérdida progresiva de neuronas asociadas al control de la movilidad de las extremidades y así existen cada vez más personas que padecen la enfermedad de Alzheimer (EA) y la enfermedad de Parkinson (EP). La enfermedad de Parkinson es conocida por la presencia en el paciente de temblor, rigidez muscular y lentitud en los movimientos (bradicinesia). Además, lo acompañan otros síntomas como cambios en el habla, problemas para hablar, cambios en la expresión facial, depresión, ansiedad, psicosis y demencia. Lo que afecta la su vida cotidiana y a sus familiares. La EP es una enfermedad neurodegenerativa progresiva que trae consigo un amplio espectro de trastorno del movimiento, incluso para expertos en medicina puede resultar difícil de identificar, caracterizar y discriminar de entre otras enfermedades que causen el trastorno de movimiento. El identificar el grado de afectación del Parkinsonismo idiopático, es una tarea difícil realizar en estados tempranos y es hecho en base a varios criterios clínicos, de los cuales, los más utilizados tiene un margen de error del 5-10%. Existen una variedad de criterios esenciales para el diagnóstico del síndrome de parkinsoniano, de entre las cuales está el temblor de reposo de 4 a 6 HZ, según. Es por eso que al aplicar técnicas de reconocimiento de patrones a las señales de temblor se espera obtener la clasificación del grado de afectación de Parkinson.

Para acortar el proceso médico de diagnóstico de pruebas estándar físicas y químicas que lo hacen costoso y tardado usamos sensores que miden la aceleración en tiempo real y embebidos en pulseras ligeras con enlace bluetooth. Esto reduce costos y genera un campo de oportunidad de crear una aplicación que ayude a un mejor y rápido diagnóstico del grado de afectación de la enfermedad de Parkinson.

En el estado del arte existen muchos trabajos destinados a determinar si una persona padece la enfermedad de Parkinson o no.

Para ello se presentan trabajos como análisis wavelet que combinado con la máquina de vectores de soporte (SVM) han logrado una clasificación eficiente logrando precisión del 90.32% con intervalo de confianza de 74.2% a 97.9%. Muchas de las pruebas usan el protocolo de tapping de dedos colocando los sensores en los dedos y el paciente debía tocar su dedo índice del pulgar 10 veces rápidamente. En otro trabajo [Fraiwan

et al., 2016] el sensor del sistema se encuentra en los teléfonos móviles para medir la aceleración de la mano del paciente usando grabaciones de 21 pacientes con enfermedad de Parkinson y 21 sujetos sanos. Se obtuvo una precisión del 95%. [Kim et al., 2018] usa una red neuronal de convolución (Convolution Neuron Network) para diferenciar la gravedad de los síntomas medidos por un dispositivo portátil en 92 pacientes con enfermedad de Parkinson y utilizando un acelerómetro para usar en la muñeca de pacientes. [Perumal and Sankar, 2016], investigaron usar las características de la marcha y el temblor para una detección temprana y monitoreo de la enfermedad de Parkinson de sujetos sanos y con Parkinson. [Yang et al., 2016] estudiaron la correlación de los temblores de las manos y concluyeron que la medición de triangulación de la línea láser es una operación no invasiva, sin contacto. Finalmente, [Gupta et al., 2018] mejora el diagnóstico de la enfermedad de Parkinson, usando el algoritmo de búsqueda de cuervos y logra predecir la enfermedad de Parkinson con un 100%.

Una vez que se diagnostica plenamente a un paciente con parkinson se le clasifica en cinco niveles o etapas según la severidad de los síntomas. [Guerrero Díaz, 2006], [Hawkes et al., 2010]

**Etapas 1.** Los síntomas en la primera etapa son los temblores de un solo lado del cuerpo y sufren pérdida del balance en un hemisferio del cuerpo. Suele presentarse en las extremidades y con mayor frecuencia en reposo o con alguna tensión emocional.

**Etapas 2.** El paciente experimenta una falta del balance y dificultad para caminar en ambos lados de su cuerpo. Al ser una enfermedad progresiva se podrá observar que la postura del sujeto cambia.

**Etapas 3.** El paciente no puede realizar sus actividades cotidianas ya que es incapaz de pararse o caminar sin un apoyo. En esta etapa ya se observan movimientos extremadamente lentos.

**Etapas 4.** Se manifiestan varios síntomas adicionales y la persona es incapaz de terminar sus actividades cotidianas sin un apoyo y necesita un sistema o del auxilio de una persona capacitada para su cuidado y la lentitud y rigidez son más severas en esta etapa.

**Etapas 5.** Finalmente, ya no realiza ninguna actividad y los temblores son extremos, se

requiere de personal calificado, sufre dolor al estar de pie, aún más al caminar y por la falta de equilibrio suele andar en sillas de ruedas o acostados en una cama.

## 2 METODOLOGÍA

La metodología del problema se reduce a tres grandes procesos, el primero es el proceso de captura de datos, el segundo es procesar los datos y finalmente el uso de técnicas de reconocimiento de patrones para clasificar el grado de afectación de la enfermedad de Parkinson usando algoritmos de clasificación y se puede ver en detalle en la siguiente gráfica.

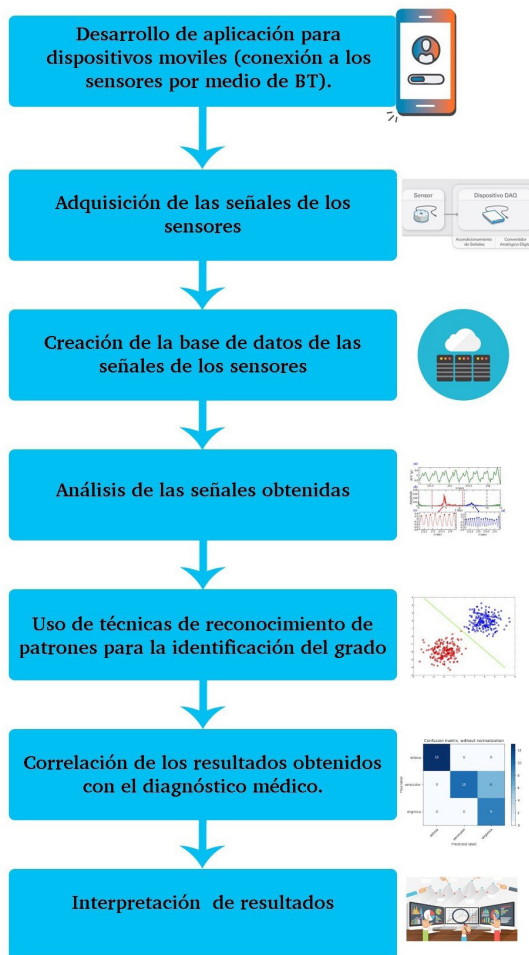


Figura1. Diagrama de bloques de la Metodología.

### 2.1 Desarrollo de la aplicación para dispositivos móviles.

Se requiere de una aplicación para dispositivos móviles obtener de manera no invasiva los datos. Se desarrollará una aplicación en un teléfono inteligente de gama baja con un sistema Operativo Android, Quad Core de 1.3 Ghz, Memoria RAM, 1 GB, Memoria Interna 8 GB y con bluetooth. Pantalla de 5 pulgadas y cámara de solo 8 Mpixeles.

La aplicación en el móvil es la encargada de leer vía inalámbrica por medio de bluetooth las señales que provienen de una pulsera capaz de medir y transmitir los datos al celular.

El formulario de registro muestra los siguientes campos y botones:

- Registro** (encabezado)
- Número de paciente** (campo de texto)
- Edad** (menú desplegable)
- Genero** (menú desplegable)
- Etapa** (menú desplegable)
- DNI** (campo de texto)
- Botón **MOSTRAR DATOS**
- Botón **REGISTRAR** (verde)
- Texto: **Registrar y mostrar transmisión de sensores para guardar**

Figura 2: Formulario de registro

La Figura 2, muestra la pantalla de registro del individuo antes de empezar a registrar los datos de los sensores, los campos a completar son: Número de paciente, edad, Género y Etapa, el grado de afectación del individuo y DNI, son caracteres que sirven para la identificación del individuo en caso de que se repita el número de usuario.

La pulsera o smartwatch cuenta con otros sensores, pero solamente el acelerómetro es utilizado en sus tres dimensiones. Monitor de ritmo cardíaco, Acelerómetro de tres ejes, girómetro, GPS, Micrófono, Sensor de luz ambiental, Sensor galvánico de respuesta cutánea, Sensor UV, Sensor de temperatura de la piel, Sensor

capacitivo y Barómetro.

Tanto los algoritmos como el entorno se realizaron en el IDE Spyder en su versión 3.3.6. En una computadora portátil Macbook Pro 2017, con 8 GB de memoria RAM, procesador Intel(R) Core (TM) i5 CPU de dos núcleos ambos con una velocidad de 2.40 GHz y Turbo Boost a 3.2 Ghz. La pulsera inteligente es una Microsoft Band 2 que cuenta con 13 sensores, de los cuales solo son necesarios aquellos sensores que registran la vibración o temblor, el pulso cardiaco y la temperatura.

Respecto de los participantes fueron 37 (edad: 25 a 71 años) tomaron parte de los experimentos. En detalle, el grupo compuesto por 25 sujetos sanos, mientras que el grupo de sujetos con la enfermedad de Parkinson por 12 sujetos, 4 sujetos con etapa 1, 5 sujetos con etapa 2 y 3 sujetos con etapa 3.

Para el proceso de captura de los datos o señales de los individuos se diseñó un protocolo, este consiste en colocar al sujeto sentado cómodamente en un asiento con respaldo, deber 'a flexionar su brazo en forma de L a unos 90 grados, esto en el brazo donde se coloca la pulsera censora (brazo con mayor afectación). El periodo de captura consta de 10 segundos, en los cuales durante este tiempo se registra la vibración, el pulso y la temperatura. Ver Figura 4.7

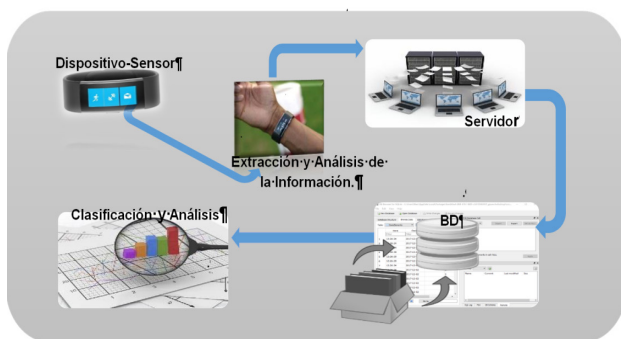


Figura 3. Captura de datos.

## 2.2 Creación de la base de datos y adquisición de las señales de los sensores

Las señales se obtendrán a través de la conexión de los sensores embebidos en la pulsera inteligente (véase Figura 4) con el teléfono móvil vía bluetooth. La velocidad de muestreo del acelerómetro de vibración es de 60 Hz. Los datos se almacenan en una base de datos en la nube con la plataforma utilizada Firebase y se hace uso del API REST de Firebase para conectar Python a la

base de datos. Finalmente, los datos se transforman a un Dataframe y se guarda en un archivo con extensión .csv.



Figura 4: Pulsera Microsoft Band 2.

## 2.3 Filtrado y procesado de la señales digitales.

Para una señal de eléctrica, el valor eficaz o rms (Root Mean Square) o raíz cuadrática media de una señal de corriente alterna, es el valor equivalente de una señal de corriente directa (Ver Figura 5). El valor eficaz de una señal se calcula sumando el cuadrado de todos los valores de una señal y dividiendo entre el número de valores sumados de acuerdo a la expresión matemática.

$$V_{rms} = \sqrt{\frac{1}{T} \int_0^T v^2(t) dt} \quad (1)$$




Figura 5. Representación de una señal de AC y DC equivalente.

El valor Máximo o Valor Pico y Valor mínimo o pico negativo en electricidad y electrónica, se denomina valor de pico de una corriente periódica a la amplitud o valor máximo de la misma. Por otra parte, el Valor mínimo, también llamado pico negativo, es la amplitud o valor mínimo de la misma señal [Miguel, 2014]. El offset de una señal es un voltaje de directa (DC) que se le suma a una señal AC para obtener un desplazamiento en la amplitud de dicha señal, ya sea positivo o negativo. En cuando se desea comparar diferentes señales es recomendable eliminar el factor DC o también llamado offset, dado que permite ver la diferencia de amplitud

de la señal ya que dichas señales tendrían un valor DC de 0. [Miguel, 2014].

## 2.4 Clasificadores de datos

En el proceso de clasificación, se usaron solo 7 clasificadores (Random Forest, Decision Tree, Naive Bayes, K-NN, LDA, SVM, MLP). La selección de las variables fue solamente usar los valores RMS, Máximo y Mínimo de la señal y con ello ahorrar drásticamente el tiempo de ejecución. [Mohssen et al., 2017] [Clifton, 2016] [Isasi Viñuela and Galván León, 2004].

### Clasificador Naive Bayes

Los clasificadores de Naive Bayes son simples clasificadores probabilísticos con su fundamento en la aplicación del teorema de Bayes con el supuesto de una fuerte independencia (Naive) entre las características. La siguiente ecuación establece el teorema de Bayes en términos matemáticos:

$$P(A|B) = \frac{P(A)P(B|A)}{P(B)} \quad (2)$$

donde A y B son eventos  $P(A|B)$  y  $P(B)$  son las probabilidades a priori de A y B sin tener en cuenta el uno al otro.  $P(A|B)$ , también llamada probabilidad posteriori, es la probabilidad de observar el evento A dado que B es verdadero.  $P(B|A)$ , también llamada probabilidad, es la probabilidad de observar el evento B teniendo que A es verdadero.

### Clasificador de K Vecinos más cercanos (K-NN)

En el reconocimiento de patrones, el algoritmo de vecinos más cercanos k (o k-NN para abreviar) es un método no paramétrico utilizado para clasificación y regresión. En ambos casos, la entrada consiste en los k ejemplos de entrenamiento más cercanos en el espacio de características.

En el reconocimiento de patrones, el algoritmo de vecinos más cercanos k (o k-NN para abreviar) es un método no paramétrico utilizado para clasificación y regresión. En ambos casos, la entrada consiste en los k ejemplos de entrenamiento más cercanos en el espacio de características.

Clasificación o regresión: En la clasificación k-NN, la salida es una membresía de clase. Un objeto se clasifica

por mayoría de votos de sus vecinos, y el objeto se asigna a la clase más común entre sus k-NN (k es un número entero positivo, generalmente pequeño). Si  $k = 1$ , entonces el objeto simplemente se asigna a la clase de ese vecino más cercano. En la regresión k-NN, la salida es el valor de la propiedad del objeto. Este valor es el promedio de los valores de su k-NN. k-NN es un tipo de aprendizaje basado en instancias, o aprendizaje diferido, donde la función solo se aproxima localmente y todos los cálculos se aplazan hasta la clasificación. El algoritmo k-NN se encuentra entre los algoritmos de aprendizaje automático más simples.

### Red neuronal perceptrónica

Una red neuronal es un modelo matemático de razonamiento inspirado en las redes neuronales biológicas, que es el sistema nervioso central en un cerebro animal. El perceptron más simple de ANN, inventado en 1957 por Frank Rosenblatt y consta de una sola neurona que puede recibir múltiples entradas y produce una sola salida para clasificar clases separables linealmente, mediante la búsqueda de cualquier hiperplano m-dimensional en el espacio de características que separa las instancias de las dos clases. Requiere una base de datos para ponderar los pesos de la red en un proceso conocido como entrenamiento.

### El algoritmo de retropropagación (Backpropagation)

El algoritmo de retropropagación consiste en dos etapas: La etapa de avance donde las entradas se alimentan a la red y la salida se calcula en las capas oculta y de salida. El error de predicción se calcula con la capa de salida, y este error se propaga hacia atrás para ajustar los pesos. Este paso se llama retropropagación. El algoritmo se utiliza para minimizar la suma de error al cuadrado utilizando el método decente de gradiente.

### Análisis discriminante lineal (LDA)

El análisis discriminante lineal (LDA), o el análisis de función discriminante es una generalización de la discriminante lineal de Fisher, un método utilizado en estadística, reconocimiento de patrones y aprendizaje automático para encontrar una combinación lineal de características que caracteriza o separa dos o más clases de objetos o eventos. La combinación resultante se puede

usar como un clasificador lineal o para la reducción de la dimensionalidad antes de la clasificación posterior.

### Máquina de Vectores de Soporte (Support Vector Machine SVM)

En el aprendizaje automático, las máquinas de vectores de soporte (SVM); la red de vectores de soporte son modelos de aprendizaje supervisados con algoritmos de aprendizaje asociados que analizan datos y reconocen patrones utilizados para el análisis de clasificación y regresión. Dado un conjunto de ejemplos de entrenamiento, cada uno marcado por pertenecer a una de dos categorías, un algoritmo de entrenamiento de máquina de vectores de soporte construye un modelo que asigna nuevos ejemplos en una categoría u otra, convirtiéndolo en un clasificador lineal binario no probabilístico.

### Bosques aleatorios (Random Forest)

Los bosques aleatorios o los bosques de decisión aleatorios son un método de aprendizaje conjunto para la clasificación, la regresión y otras tareas que opera construyendo una multitud de árboles de decisión en el momento del entrenamiento y generando la clase que es

el modo de las clases (clasificación) o la predicción media (regresión) de los árboles individuales. Los bosques de decisión aleatorios corrigen el hábito de los árboles de decisión de sobreajustar a su conjunto de entrenamiento. Los resultados son válidos para la clasificación de datos de personas con la enfermedad de Parkinson, además cabe mencionar que se tendrá un mayor grado de confiabilidad mientras la base de datos sea más grande. Para el proceso de la clasificación, se realizará de dos formas, una que es la normal o tradicional mientras que la segunda es utilizando la técnica de clasificación en cascada, al usar diferentes clasificadores para obtener diferentes resultados se podrá observar que clasificador obtiene mejores resultados.

### 3 RESULTADOS

En las Figuras 6 y 7 se observan las señales de individuos que declaran tener la enfermedad de Parkinson de etapa 1, 2 y 3 respectivamente en ese orden, en dichas señales se aprecia que la amplitud es mayor que la amplitud de la señal del sujeto que declara estar sano, con referencia de las figuras de las señales anteriores se aprecia que conforme la etapa de la enfermedad de Parkinson es más elevada, es mayor la frecuencia en la que la varía la amplitud.



Figura 6. La señal de vibración de un sujeto sano y otro con Parkinson.




Figura 7. La señal de vibración etapa 2 y 3 de Parkinson.

Después se generan características de las señales, tales como Mínimo, Máximo y Root Mean Square, las cuales son las variables utilizadas para la clasificación. En la Figura 8. Se observa como están distribuidos los datos, en el cual se aprecia su separabilidad entre cada una de las

clases, esto facilitando la clasificación. Máximo y Mínimo, donde se encuentran las 4 clases que corresponde a las primeras 3 etapas de la enfermedad de Parkinson y sujetos sanos.

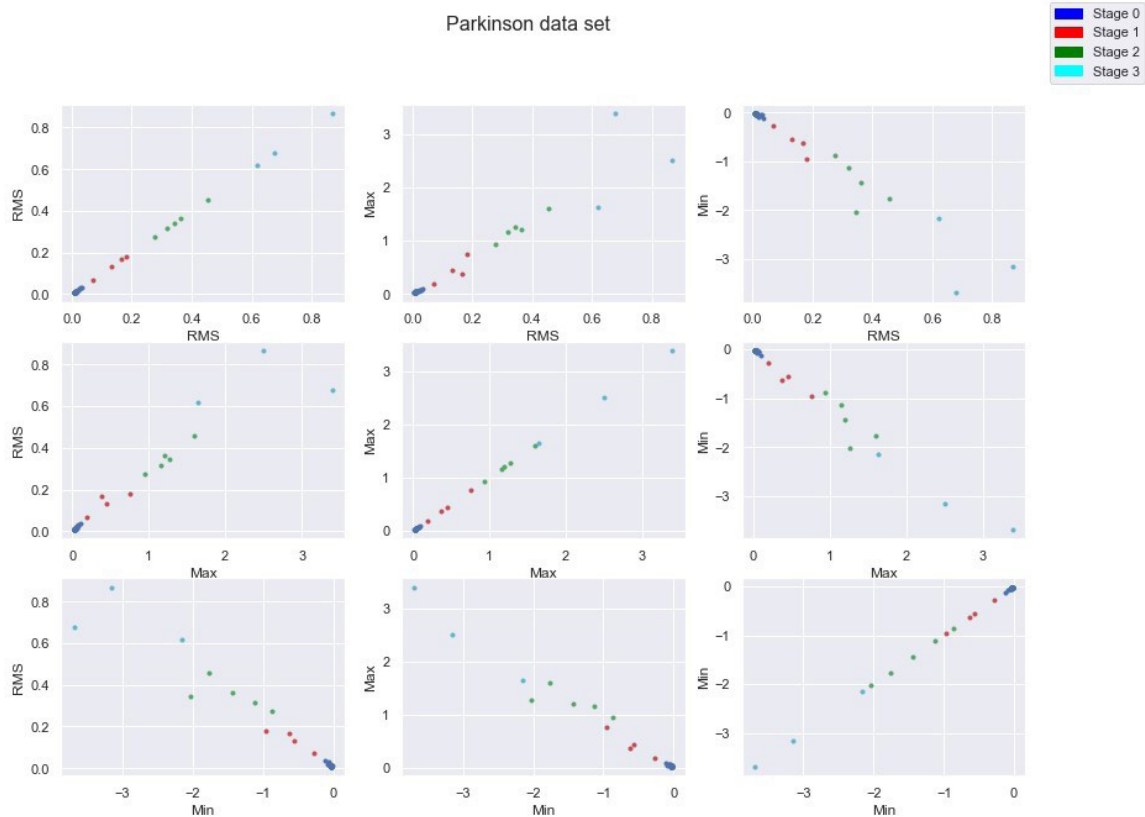


Figura 8: Grafica de datos usando las variables de RMS. Máximo y Mínimo.




Figura 9. Grafica en 3D de la base de datos usando las variables de RMS.

Se puede apreciar en las Gráficas 8 y 9 que la clase con mayores individuos es el de la etapa 0, y de ahí por qué surge el problema de la base de datos no balanceada. A continuación, se muestra el rendimiento de clasificación que se obtiene al aplicar clasificación y se implementa una validación cruzada de Leave one Out.

etiqueta o etapa de diagnóstico original del sujeto que tiene la enfermedad de Parkinson. La matriz de confusión es de ayuda para esta finalidad, donde cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real.

### 3.1. Matrices de confusión

En este apartado se realizará la comparación de los resultados de predicción de cada clasificador con la

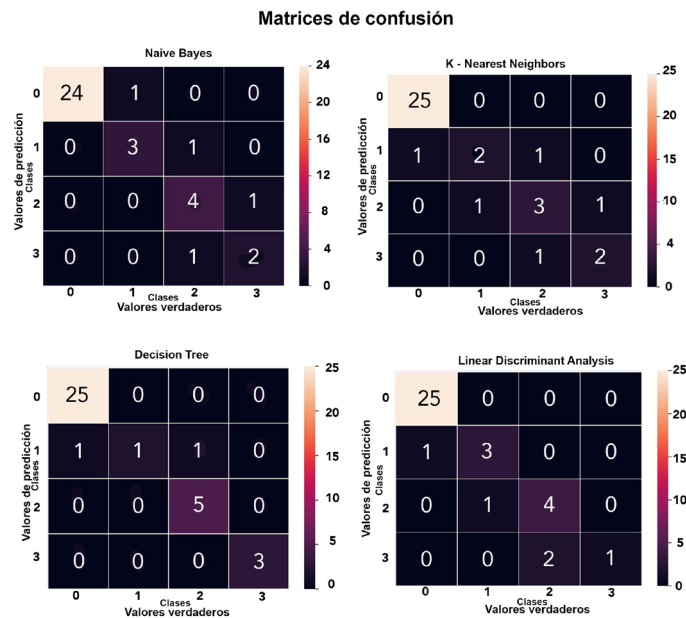


Figura 10. Matrices de confusión del resultado de los clasificadores

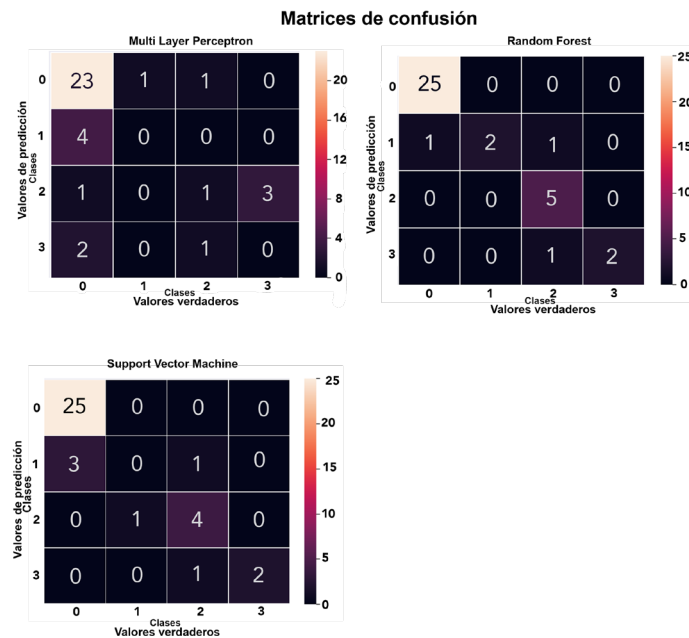


Figura 11. Matrices de confusión del resultado de los clasificadores

*Tabla con el resultado de clasificación de cada uno de los diferentes clasificadores, usando validación cruzada Leave One Out.*

Clasificador	Porcentaje de clasificación
Decision Tree	94.5
Random Forest	91.8
Naive Bayes	89.1
K Near Neighbours	86.4
Linear Discriminant Analysis Classification	84.2
Linear Support Vector Machines	83.7
Multi-Layer Perceptron	64.86

En las Figuras 10 y 11 se presentan las matrices de confusión de los distintos clasificadores aplicados al cual le corresponde el porcentaje de clasificación que está en la tabla 1, se puede apreciar que solo los clasificadores Random Forest y Decision Tree superan el 90% de acierto de clasificación. Comparativamente con el resultado de clasificación de los demás clasificadores, el que tiene menor porcentaje de clasificación es el Multi Layer Perceptron con 64.86%.

#### 4 CONCLUSIONES

En el trabajo se usó un sistema no invasivo de medición de vibración para grabar la señal de vibración de la muñeca de individuos, el cual, aplicando técnicas de reconocimiento de patrones, se logró la clasificación del grado de afectación de la enfermedad de Parkinson, se usaron 7 importantes y conocidos clasificadores distintos para obtener diferentes aciertos de clasificación. Hemos estudiado el papel del síntoma de temblor en muñeca para detectar la enfermedad de Parkinson el potencial de ser herramienta para un diagnóstico de las etapas de la enfermedad de Parkinson. En el experimento todos los clasificadores fueron exitosos y se puede usar para discriminar una clase de otra, se esperaría un acierto de clasificación mayor al obtenido dado que las clases son linealmente separables. Dichos resultados pueden conducir a diferentes tratamientos resultantes para los sujetos con la enfermedad de Parkinson, dependiendo de como se ha clasificado su temblor etapa de la enfermedad de Parkinson.

## REFERENCIAS

1. [LAC, 2018] (2018). Using echo state networks for classification: A case study in parkinson's disease diagnosis. *Artificial Intelligence in Medicine*, 86:53 – 59.
2. [Barranco Quintana, 2016] Barranco Quintana, J. L. (2016). Enfermedad de alzhéimer, parkinson y cafe: Revisión sistemática.
3. [Breiman, 2001] Breiman, L. (2001). Random forest. *Machine Learning*, 45(5):5 –32.
4. [Cai et al., 2018] Cai, G., Lin, Z., Dai, H., Xia, X., Xiong, Y., Horng, S.-J., and Lueth, T. C. (2018). Quantitative assessment of parkinsonian tremor based on a linear acceleration extraction algorithm. *Biomedical Signal Processing and Control*, 42:53 – 62.
5. [Camara et al., 2015] Camara, C., Isasi, P., Warwick, K., Ruiz, V., Aziz, T., Stein, J., and Bakstein, E. (2015). Resting tremor classification and detection in parkinson's disease patients. *Biomedical Signal Processing and Control*, 16:88 – 97.
6. [Chapra and Canale, 2007] Chapra, S. C. and Canale, R. P. (2007). Aproximación de Fourier, pages 539 – 575. 5 editions.
7. [Clifton, 2016] Clifton, D. A. (2016). *Discrete-time Signals and Systems (Chapter 1)*, pages 59 – 199.
8. [Cruz, 2003] Cruz, Carlos Aviles; Rodriguez, E. R. (2003). *Teoría de muestreo*, pages 109–122. 1 edition.
9. [Del Carmen Ojeda Lo´pez et al., 2009] del Carmen Ojeda Lo´pez, M., Weber, F. R., and Sa´nchez, L. E. A. (2009). Diagn´ostico diferencial del temblor. *Acta M´edica Grupo Angeles´*, 7:143 – 149.
10. [Fernando de Carvalho Gomes, 2016] Fernando de Carvalho Gomes, J. G. R. M. (2016). Learning optimal decision list as a metaheuristic search for diagnosis of parkinson's disease. Springer International Publishing AG, 10122:391 – 401.
11. [Forouzan, 2013] Forouzan, J. A. (2013). *Data Communications and networking*.
12. [Fraiwan et al., 2016] Fraiwan, L., Khnouf, R., and Mashagbeh, A. R. (2016). Parkinson's disease hand tremor detection system for mobile application. *Journal of Medical Engineering & Technology*, 40(3):127–134. PMID: 26977823.
13. [González García, 2011] González García, Paloma; Gutiérrez Rodríguez, J. V. B. C.
14. [Guerrero Díaz, 2006] Guerrero Díaz, Ma. Teresa; Macías Montero, M. C. P. E. F. M. P. A. H. J. M. V. D. G.-L. J. (2006). *Enfermedad de Parkinson*, chapter 49, pages 507 – 517.
15. [Gupta et al., 2018] Gupta, D., Sundaram, S., Khanna, A., Hassanien, A. E., and de Albuquerque, V. H. C. (2018). Improved diagnosis of parkinson's disease using optimized crow search algorithm. *Computers Electrical Engineering*, 68:412 – 424.

## Acerca de los autores



Eduardo Ibarra Sánchez, Ingeniero en Tecnologías de la Información y Comunicación y egresado del Instituto Tecnológico de León. Actualmente estudia la carrera de posgrado maestría en ciencia de la comunicación en el mismo Instituto y es becario Conacyt.




Juan Francisco Mosiño, Doctor en Ciencias por el Centro de Investigaciones en Óptica, Miembro del Sistema Nacional de Investigadores desde el 2002. Realizó estudios previos de Maestría en Ingeniería Eléctrica y Licenciatura en Ingeniería en Electrónica y Comunicaciones en la Universidad de Guanajuato. El Dr. Mosiño está adscrito al Tecnológico Nacional de México en el Instituto Tecnológico de León desde 2015.



María del Rosario Baltazar Flores, Doctora en ciencias e ingeniera en electrónica y comunicaciones por la Universidad Autónoma de Zacatecas. Actualmente es miembro del SNI Nivel I; ingresó al Instituto Tecnológico de León en el año de 2003. Ha desarrollado múltiples proyectos multidisciplinarios combinando las técnicas de Inteligencia Artificial (IA) con procesos de cómputo ubicuo y comunicación de datos en dispositivos móviles.



Raúl Santiago Montero, Ingeniero en comunicaciones y electrónica por la ESIME IPN. Maestro en ciencias de la comunicación por el Centro de investigación en Computación del IPN. Doctor en Ciencias (Computación) por el IIMAS-UNAM. Profesor investigador del TNM Campus León. Premio Nacional Mejor tesis maestría ANIIE 2004. Miembro del SNI Nivel 1.



Emmanuel Martínez Hernández, Ingeniero en informática egresado del Instituto Tecnológico de Iguala y egresado de la maestría en ciencia de la computación del Instituto Tecnológico de León.