



**Clasificador de Máquinas de Vectores de Soporte
para el Apoyo en la Detección del Grado I y II de
Osteoartritis de Rodilla Según Kellgren- Lawrence
Mediante Imágenes de Rayos X.**

María José Sánchez Vásquez

Carlos Alberto Bastos Claros

Universidad Antonio Nariño

Facultad de Ingeniería Mecánica, Electrónica y Biomédica

Neiva, Colombia

2020

Clasificador de Máquinas de Vectores de Soporte para el Apoyo en la Detección del Grado I y II de Osteoartritis de Rodilla Según Kellgren- Lawrence Mediante Imágenes de Rayos X.

María José Sánchez Vásquez

Carlos Alberto Bastos Claros

Proyecto de grado presentado como requisito parcial para optar al título de:

Ingeniero Electrónico

Director (a):

MSc. Ing. Jennifer Triana

Línea de Investigación:

Análisis de Información Biomédica

Universidad Antonio Nariño

Facultad de Ingeniería Mecánica, Electrónica y Biomédica

Neiva, Colombia

2020

Dedicamos este trabajo principalmente a Dios porque nos da vida y nos permite llegar a este momento tan importante en nuestra formación profesional. A nuestra familia, que nos ha estado apoyando a lo largo de nuestra carrera y vida universitaria, convirtiéndolos en el pilar más importante y mostrándonos siempre su amor y apoyo incondicional, independientemente de nuestras diferencias de opinión. Para todas las personas especiales que nos acompañan en esta etapa, y han contribuido a nuestra formación profesional y formación humana.

Agradecimientos

Principalmente queremos agradecer a Dios por todas las bendiciones, a nuestros padres que nos brindaron ejemplo de trabajo y honestidad, y agradecerles su apoyo incondicional y su paciencia para este proyecto de investigación.

También queremos agradecer a la Universidad Antonio Nariño, en especial a la sede de Neiva, a toda la Facultad de Ingeniería, al plantel de profesores y al personal administrativo por organizar el programa de ingeniería electrónica.

Queremos expresar nuestro más sincero agradecimiento a la Ingeniera Jennifer Triana, quien es la principal colaboradora en todo el proceso. Su orientación, conocimiento, enseñanza y cooperación nos permitieron realizar este trabajo.

Finalmente, para nuestros profesores, en especial la Coordinadora Académica de la sede de Neiva la Ingeniera Andrea Milena Marín Zambrano, su enseñanza con su preciado conocimiento nos ha permitido desarrollarnos como profesionales, gracias a toda nuestra facultad y a cada maestro que tuvimos en nuestra carrera por la paciencia, dedicación, apoyo incondicional y amistad.

Resumen

El propósito de este proyecto es implementar un clasificador de Máquina de Vectores de Soporte (SVM), basándose en el método de clasificación de la Escala de Kellgren-Lawrence (KL), y la utilización de imágenes de rayos x (RX), con el objetivo de apoyar en el diagnóstico del especialista en traumatología en la detección del grado Osteoartritis (OA) de rodilla de acuerdo a la clasificación antes mencionada, en pacientes de Ortopedia y Traumatología de la Clínica Medilaser de Neiva tratados entre los meses de junio y agosto de 2020.

Se espera que este proyecto permita categorizar el grado de Osteoartritis (OA) de rodilla apoyando el diagnóstico del especialista, de tal manera que se minimice la cantidad de pruebas además de las nombradas anteriormente para determinar un diagnóstico de esta patología.

Palabras claves: Osteoartritis, SVM, Aprendizaje de máquina, Características Kellgren-Lawrence, Rayos X

Abstract

The purpose of this project is to implement a Support Vector Machine (SVM) classifier, based on the Kellgren-Lawrence (KL) grade classification method, and the use of X-ray images (XR), with the objective of supporting the trauma specialist's diagnosis in the detection of knee Osteoarthritis (OA) grade according to the above-mentioned classification, in Orthopedic and Traumatology of the Medilaser Clinic of Neiva treated between the months of June and August 2020.

It is expected that this project will allow the categorization of the degree of Osteoarthritis (OA) of the knee supporting the diagnosis of the specialist, in such a way that the amount of tests in addition to those previously named is minimized to determine a diagnosis of this pathology.

Keywords: Osteoarthritis, SVM, Machine Learning, Kellgren-Lawrence Features, X-Ray

Contenido

Lista de figuras	9
Lista de tablas	11
Lista de abreviaturas	12
Introducción	13
Planteamiento del problema	16
Objetivos	18
Objetivo General.....	18
Objetivos Específicos	18
1. Marco teórico.....	19
1.1 Anatomía de la Rodilla.....	19
1.1.1 La Osteoartritis de rodilla (OA).....	20
1.1.2 Clasificación de Kellgren-Lawrence de la Osteoartritis	21
1.2 Imagen Digital	23
1.2.1 ¿Qué es una imagen digital?	23
1.2.2 Píxel.....	24
1.2.3 Resolución de una imagen.....	24
1.2.4 Escala de grises	24
1.3 Preprocesamiento de imágenes médicas (rayos X)	24
1.4 Ecuador de Histogramas.....	25
1.5 Filtro Wiener.....	26
1.6 Segmentación de Imágenes Médicas	27
1.6.1 Método de Otsu para la Segmentación de Imágenes	27
1.7 Extracción de Características	29
1.8 Máquinas de Vectores de Soporte (Support Vector Machine (SVM))	30
1.9 Matriz de Confusión	36
2. Metodología.....	39
2.1 Bases de datos utilizadas	40
2.2 Fase de Preprocesamiento de la base de datos.....	45
2.3 Implementación del Filtro Wiener (Wiener Filter)	48
2.4 Implementación del Ecuador de Histogramas (Histogram Equalization).....	50
2.5 Fase de Segmentación de la base de datos	52
2.6 Fase de Extracción de Características de la base de datos	54

<u>Contenido</u>	8
2.7 Fase de Clasificación de la SVM.....	56
3. Análisis de Resultados.....	60
3.1 Limitaciones	64
3.2 Discusiones.....	64
4. Conclusiones y recomendaciones	65
4.1 Conclusiones.....	65
4.2 Recomendaciones	66
5. Bibliografía.....	67

Lista de figuras

<i>Figura 1-1: Anatomía de la rodilla</i>	20
<i>Figura 1-2: Ejemplo de los distintos grados según la escala de Kellgren-Lawrence</i>	23
<i>Figura 1-3: Presencia de osteofitos</i>	25
<i>Figura 1-4: Hiperplano de separación</i>	32
<i>Figura 1-5: Casos de hiperplano separación</i>	33
<i>Figura 1-6: Componentes de SVM</i>	34
<i>Figura 1-7: Datos no separables linealmente</i>	34
<i>Figura 1-8: Aplicación de la función Kernel a un grupo de datos</i>	36
<i>Figura 1-9: Truco Kernel</i>	36
<i>Figura 1-10: Clasificación de margen suave</i>	38
<i>Figura 2-1: Diagrama de bloques para la segmentación de la imagen de Rayos X</i>	42
<i>Figura 2-2 Imagen Original de Rayos x</i>	42
<i>Figura 2-3: Muestras de imágenes de grado I de la base de datos propia</i>	44
<i>Figura 2-4: Muestras de imágenes de grado II de la base de datos propia</i>	45
<i>Figura 2-5: Muestras de imágenes de grado I de la base de datos (Knee Osteoarthritis Severity Grading Dataset)</i>	46
<i>Figura 2-6: Muestra de imágenes grado II de la base de datos (Knee Osteoarthritis Severity Grading Dataset)</i>	47
<i>Figura 2-7: Diagrama de bloques de pasos para el Preprocesamiento de la imagen de Rayos X de rodilla</i>	48
<i>Figura 2-8: Se muestra la imagen de entrada RGB original y a la salida se muestra la región de interés (ROI) y en escala de grises</i>	49
<i>Figura 2-9: Imagen de entrada RGB original y a la salida se muestra en escala de grises</i>	50
<i>Figura 2-10: Imagen antes y después de ser tratada con el Filtro Wiener</i>	51
<i>Figura 2-11: Proceso para el Filtrado de Wiener</i>	52

<u>Lista de figuras</u>	10
<i>Figura 2-12: Ecuación de Histograma</i>	53
<i>Figura 2-13: Pasos para la Ecuación de Histograma</i>	54
<i>Figura 2-14: Proceso para la segmentación de las imágenes</i>	55
<i>Figura 2-15: Pasos para la segmentación de las imágenes</i>	56
<i>Figura 2-16: Imagen con las regiones de interés</i>	57
<i>Figura 2-17: Proceso de extracción de características con dos regiones de interés</i>	58
<i>Figura 2-18: Clasificación SVM</i>	60
<i>Figura 2-19: Pasos para la evaluación de la SVM</i>	61
<i>Figura 3-1: Matriz de confusión con los resultados base de datos propia, utilizando Kernel Polinomial</i>	64
<i>Figura 3-2: ROC primera SVM polinómica, relación verdaderos positivos y falsos positivos</i>	64
<i>Figura 3-3: Matriz de confusión con los resultados base de datos propia, utilizando RBF</i> .65	
<i>Figura 3-4: ROC primera SVM RBF, relación verdaderos positivos y falsos positivos</i>	65
<i>Tabla 3-5: Matriz de confusión con los resultados base de datos (Knee Osteoarthritis Severity Grading Dataset)</i>	66
<i>Figura 3-6: ROC segunda SVM lineal, relación verdaderos positivos y falsos positivos</i>	66

Lista de tablas

<i>Tabla 1-1. Descripción escala de KL</i>	22
<i>Tabla 1-2. Matriz de confusión</i>	37

Lista de abreviaturas

Abreviatura	Término
<i>SVM</i>	Máquina de soportes vectorizado
<i>OA</i>	Osteoartritis
<i>KL</i>	Kellgren-Lawrence
<i>RX</i>	Rayos x
<i>ML</i>	Máquinas de aprendizaje
<i>PCA</i>	Análisis de componentes principales
<i>GLCM</i>	Matriz de co-ocurrencia de nivel de gris
<i>IRM</i>	Imagen de resonancia magnética
<i>JSN</i>	Estrechamiento del espacio articular
<i>LCP</i>	Ligamento cruzado posterior
<i>LCA</i>	Ligamento cruzado anterior
<i>TC</i>	Tomografía computarizada
<i>HE</i>	Ecualización de histograma
<i>Otsu</i>	Segmentación por Umbral
<i>VP</i>	Verdadero positivo
<i>VN</i>	Verdadero Negativo
<i>FP</i>	Falso positivo
<i>FN</i>	Falso negativo
<i>DVD</i>	Disco versátil digital
<i>ROC</i>	Indicador de tasa de cambio
<i>ROI</i>	Retorno de inversión
<i>AUC</i>	Área bajo la curva
<i>RBF</i>	Kernel de Base Radial
<i>PNG</i>	Portable Network Graphics

Introducción

A nivel mundial, la rodilla es una de las articulaciones más afectadas por la Osteoartritis (OA). Esta enfermedad afecta principalmente a mujeres y ancianos, aunque recientemente ha sido diagnosticada en jóvenes (Capapé, 2020). Perjudicando la masa ósea del paciente, aumentando así el sedentarismo y la aparición de enfermedades más complejas como hipertensión, enfermedades cardiovasculares, etc. (Felson, 1988).

La OA de rodilla se considera una enfermedad crónica, de proceso lento que puede no variar durante extensos periodos, pero es posible que logre llegar a causar incapacidad funcional (Cartas Solís U, 2015). Con el avanzado desarrollo de la tecnología y el auge de los sistemas de cómputo, surgieron ciencias como el procesamiento de imágenes (Russ, 1990) y el aprendizaje de maquina (ML) que permitieron entre muchas otras cosas generar herramientas de soporte al diagnóstico médico (Guo H, 2009).

Lu Huanjun et al. (HUAN-JUN, 2005) enfatizaron en la importancia de elegir la función del Kernel adecuada y sus parámetros. Los experimentos realizados muestran que el algoritmo propuesto en este estudio puede encontrar efectivamente la mejor función del Kernel y sus parámetros, y debido a que el tamaño del vector de soporte afecta su desempeño.

Yan Yang (Yang Y, 2012) proponen una técnica para mejorar el clasificador de SVM para que este detecte las microcalcificaciones. En este trabajo, se consideraron dos técnicas diferentes, SVM de vector de soporte virtual y la otra es SVM de Vector tangente. Cuando se implementan estas dos técnicas, su resultado es que el vector tangente SVM logra un mejor desempeño, ya que el porcentaje encontrado en este trabajo es 96.3% para el vector tangente SVM y 94.5% para el soporte virtual SVM.

Además de lo anterior, Hernán Vargas, Álvaro Orozco y Mauricio Álvarez (Cardona H.D.V, 2014) realizaron una investigación con el propósito de diseñar un sistema para cuantificar e identificar la gravedad de la artrosis de rodilla (OA) mediante SVM. Existe una base de

datos de 80 imágenes de rayos X de la rodilla derecha de pacientes con OA, utilizando la distribución gaussiana para seleccionar los datos. Los resultados experimentales muestran que el desempeño del método de investigación creado y desarrollo fue del 94,33%. Por tanto, se concluye que el nuevo sistema utilizado es significativamente mejor que otros sistemas.

Además, Sandeep Kumar Sahu, Arun K. Pujari, demostraron que ensamblar clasificadores binarios resulta mejor que usar clasificadores multiclase. Esta muestra un método empírico, en comparación con la mayoría de los principales clasificadores SVM de clases múltiples, que puede proporcionar una mayor precisión y menos sobrecarga computacional (Sahu SK, 2015).

Dattatray Ishwar Navale, Ravindra S. Hegadi, (Navale DI, 2015) dividieron 40 radiografías de rodilla en 9 bloques de 20 pacientes sanos y 20 pacientes diagnosticados con osteoartritis. Posteriormente implementaron una SVM para verificar el desempeño del algoritmo de análisis de textura utilizado para extraer las características estadísticas de la imagen para así detectar cuáles pacientes presentaban esta patología.

Saruar Alam y Moonsoo Kang (Alam S, 2016), realizaron un proyecto de investigación basado en análisis de componentes principales (PCA), observando cómo se comporta la SVM lineal y SVM multi Kernel, buscando comparar y distinguir entre personas sanas y pacientes con enfermedad de Alzheimer. El método propuesto obtuvo más del 85% de acierto con la SVM multi Kernel, pasando por encima del 84% de la SVM lineal.

En 2016, Sandeep Sharma et al. (Sharma S, 2016) realizaron un estudio en el que utilizaron múltiples métodos como Extracción de características, Método de histograma, Matriz de co-ocurrencia de nivel de grises (GLCM), Técnica de detección de bordes astutos, para detectar y clasificar pacientes con osteoartritis de rodilla mediante SVM, y realizaron las pruebas correspondientes mediante diferentes técnicas (histograma Método, matriz de co-ocurrencia de nivel de gris GLCM (Gray-Level Co-Occurrence Matrix), método de detección de bordes afilados) Después de combinar estas técnicas, muestra una efectividad del 95%

en la identificación de patología, dado que las características de imagen extraídas mediante el uso de tecnología GLCM fueron adecuadas.

El uso de clasificadores SVM ha sido recurrente en el campo de la salud. En 2017, Roberto González desarrolló un proyecto directamente dirigido al sector salud (González R, 2017), con el objetivo de complementar el diagnóstico clínico de la enfermedad de Parkinson y temblor esencial; patología que tiene una gran influencia, por lo que se utilizó una máquina de vectores de soporte y la tasa de éxito fue del 95%.

Por esto, en este trabajo de investigación se presentó el desarrollo metodológico con el cual se creó un banco de imágenes para los grados I y II en la escala de Kellgren-Lawrence (KL) de Osteoartritis de rodilla mediante imágenes de rayos X, para esto se implementó métodos de preprocesamiento, segmentación y extracción de características a cada una de las imágenes respectivamente. Finalmente, se creó un modelo SVM, evidenciando la eficiencia en la detección de estos dos grados de OA por medio de una matriz de confusión.

Planteamiento del problema

La osteoartritis (OA) de rodilla también denominada artrosis de rodilla, es una patología degenerativa de las articulaciones que afecta tanto a jóvenes como a adultos mayores y que está asociada a factores genéticos, nutricionales, obesidad, actividad física elevada, menopausia, entre otros, generando en el paciente una serie de limitaciones como la pérdida de movilidad y de autonomía en las actividades diarias (Martínez Figueroa R, 2017).

El diagnóstico de la OA se realiza empleando la información suministrada por los exámenes físicos y de rayos X; estos últimos permiten al especialista emitir un diagnóstico inicial de la posible presencia de la patología en el paciente. Posterior a el resultado de RX, el médico solicita que los pacientes se realicen un examen de Resonancia Magnética (IRM) para determinar con exactitud el grado de OA en el que se encuentra su rodilla (Shamir L, 2009).

La radiografía de rodilla es una herramienta de soporte diagnóstico segura e indolora que se obtiene al exponer al paciente a pequeñas cantidades de radiación, similares a la luz visible. Los RX muestran el interior del cuerpo en diferentes tonos de blanco o negro. Esta imagen de RX tomada, muestra parte de los huesos de la rodilla como lo son el fémur (epífisis distal), la tibia y el peroné (epífisis proximal), y la rótula (Shamir, 2009), (Arregui Espinoza JM, 2016). Otro beneficio podría atribuirse a su bajo costo y alta disponibilidad. Hablando a nivel local, en la ciudad de Neiva la toma de una imagen de rayos-x puede costar en promedio \$26.000 (Fierro J, 2020).

La mayor desventaja que tienen este tipo de imágenes radiológicas es la dificultad por parte del especialista para determinar el grado I y II de OA en el que se encuentra la rodilla examinada, lo que generalmente conlleva a que el especialista se vea obligado a ordenar exámenes adicionales como la Imagen de Resonancia Magnética (IRM) (Moya-Angeler J, 2016) para hallar el grado de OA en el que se encuentra la rodilla, lo cual genera un incremento considerable de costos y tiempo de espera para el paciente, ya que una prueba de este tipo puede alcanzar un valor de \$320.000 (Fierro J, 2020), requiriendo además una disponibilidad de 7 días hábiles o más para la toma de la misma (Fierro J, 2020).

En la actualidad se está utilizando otras técnicas diagnósticas de este padecimiento tales como el estudio Kellgren-Lawrence (KL), este permite realizar una categorización de los grados de complejidad en el que se encuentra la OA, KL tiene la siguiente clasificación: Grado I: articulación con dudoso estrechamiento del espacio articular y posible osteofitos (son protuberancias óseas no maduras, que se reflejan por la presencia de una enfermedad degenerativa), Grado II: definitivos osteofitos y posible estrechamiento del espacio articular , Grado III: moderado osteofitos múltiples y estrechamiento del espacio articular definido, Grado IV: grande osteofitos, estrechamiento del espacio articular marcados (Zhang Y, 2010).

En este trabajo de grado se desarrolló un sistema de clasificación usando máquinas de vectores de soporte (SVM) para la detección de los grados I y II según la escala Kellgren-Lawrence (KL) para el diagnóstico de OA, siendo estos grados los que presentan más dificultad al momento de la detección en la revisión de las imágenes de RX. La teoría de la máquina de soporte Vectorial fue propuesta por Corinna Cortes, Vladimir Vapnik y el laboratorio de AT&T (C. Cortes and V. Vapnik, 1995), el cual tiene como objetivo encontrar un hiperplano que permita separar las dos clases. Además, en algunos trabajos se menciona un desempeño superior de los clasificadores SVM por sobre las redes neuronales tradicionales a la hora de clasificar datos (Paoletti ME, 2020), (González R, 2017).

En este contexto se pretende entonces detectar el grado de osteoartritis grado I y II en pacientes de la Clínica Medilaser de la ciudad de Neiva, según la escala de KL usando una máquina de soporte vectorial SVM como clasificador en imágenes de rayos x recolectadas entre los meses de junio y agosto del año 2020.

Objetivos

Objetivo General

Detectar el grado I y II de OA de acuerdo con la escala de KL, utilizando el clasificador SVM en imágenes de rayos x para apoyar el diagnóstico dado a los pacientes que reciben consulta ortopédica.

Objetivos Específicos

- Determinar un banco de radiografías de rodilla para la clínica Medilaser de Neiva para el entrenamiento del clasificador SVM, a partir del procesamiento de las radiografías recolectadas.
- Entrenar el clasificador SVM a partir del banco de radiografías de rodilla realizado para la clínica Medilaser de Neiva para la detección del grado I y II de OA.
- Verificar si el resultado final del clasificador SVM diseñado concuerda con el diagnóstico del especialista en Traumatología de la Clínica Medilaser de Neiva.

1. Marco teórico

En esta sección se hace una revisión de las técnicas y conceptos más relevantes asociados con el desarrollo de la investigación como lo son el preprocesamiento, segmentación, clasificación y métricas de evaluación a través del reconocimiento de patrones y el procesamiento de imágenes médicas como lo son los Rayos X. Así mismo, se comienza abarcando de manera sucinta la anatomía de la rodilla y la patología de interés (OA) siendo estas, definiciones imprescindibles para comprender el enfoque del trabajo.

1.1 Anatomía de la Rodilla

La rodilla es la articulación más grande del cuerpo humano y está compuesta por muchas estructuras, de las cuales tres huesos están involucrados principalmente, a saber, el fémur, la tibia y el hueso (Flandry, 2011), (FULKERSON J P, 1980). En la figura 1-1 se pueden observar las partes de la rodilla y su ubicación.




Figura 1-1: Anatomía de la rodilla

Fuente: (HEALTH, 2020)

La articulación de la rodilla está compuesta por una variedad de estructuras, por ejemplo; el fémur se pueden encontrar dos protuberancias óseas que cubren el cartílago articular; se puede ver que, en la articulación de la rodilla, tiene muchas estructuras de ligamentos que pueden evitar que los componentes óseos de la articulación de la rodilla se froten entre sí. El hueso está ubicado en el tendón del músculo cuádriceps, pasa a través del líquido sinovial hasta la tibia y está casi incrustado en el tendón, por lo que este queda fijo.

En la parte exterior del peroné, hay dos ligamentos que pasan a través del ligamento medial, llamados ligamento colateral lateral y ligamento colateral medial. En la articulación de la rodilla encontramos dos ligamentos importantes, llamados ligamento cruzado anterior (LCA) y ligamento cruzado posterior (LCP), ambos ligamentos estabilizan la articulación de la rodilla y evitan el desplazamiento de la rodilla, a este se le llama menisco, el menisco tiene una función muy importante para equilibrar la desigualdad entre la superficie articular del fémur y la tibia, y también aseguran la rodilla para una mejor distribución del peso (Turner A Blackburn, 1980), (Lovejoy, 2007).

1.1.1 La Osteoartritis de rodilla (OA)

La vejez, la obesidad y las lesiones articulares son los principales factores de riesgo para el desarrollo de la osteoartritis. La forma más común de osteoartritis es una enfermedad articular, que se manifiesta cuando el cartílago entre los huesos se desgasta y se rozan entre sí, causando dolor, hinchazón y trastornos del movimiento entre otros. El dolor severo es su síntoma principal y empeora con el tiempo, provocando dificultad e incapacidad para realizar las actividades diarias. Las articulaciones más afectadas son la columna vertebral, caderas, rodillas, manos, hombros y tobillos, que afectan más a las mujeres que a los hombres (Solís Cartas U, 2018), (Solís Cartas, 2014).

Para diagnosticar la osteoartritis se requieren exámenes físicos, exámenes radiológicos para comprender la pérdida de cartílago articular y, en algunos casos, también se pueden realizar exámenes de laboratorio, además de exámenes complementarios para ayudar a determinar el grado de la OA, como la resonancia magnética y la tomografía axial computarizada (Tromberg BJ). En estos casos, el tratamiento comienza con la identificación de la causa recomendando reposo para aliviar el dolor articular. Sin embargo, a medida que pasa el tiempo, cuando el desgaste articular es severo para las personas que tienen esta patología, el dolor puede aumentar y surge la necesidad de recetar analgésicos y mayor reposo; Como última instancia se opta por colocar una prótesis para el reemplazo de la articulación, este método tiene una alta tasa de éxito y puede restaurar la función y la calidad de vida del paciente (Solís Cartas U, 2018).

1.1.2 Clasificación de Kellgren-Lawrence de la Osteoartritis

El sistema de clasificación de KL (Luijckxre, 2016), es un método que permite determinar el grado de severidad o afectación de la osteoartritis haciendo uso de cinco diferentes grados de complejidad, donde se tienen en cuenta características radiológicas propias de la OA como la generación de osteofitos y el estrechamiento del espacio articular (Mark D. Kohn, 2016).

La figura 1-2 muestra los ejemplos representativos radiográficos de la OA por medio de cuatro sub-figuras (A-D) ubicadas en escala ascendente según la etapa en la que se pueda encontrar la osteoartritis permitiendo así visualizar el nivel de compromiso de la articulación del paciente. En la literatura existen algunos métodos alternos para el diagnóstico de esta patología a través de técnicas como la tomosíntesis y el análisis de textura ósea, métodos más complejos, costosos y dispendiosos, por lo cual el método de clasificación de KL es uno de los más aceptados y utilizados porque detalla el grado de complejidad en el que se encuentra la rodilla de una manera rápida (drzezo, 2017).




Figura 1-2: Ejemplo de los distintos grados según la escala de Kellgren-Lawrence. A. Grado I, B. Grado II, C. Grado III, D. Grado IV.

Fuente: (drzezo, 2017)

En la tabla 1-1, se mencionan las características de cada uno de los grados de Osteoartritis de rodilla según la escala de Kellgren-Lawrence.

Grado	Descripción
0	Sin ningún hallazgo radiológico
I	Reducción sospechosa en el espacio articular y desarrollo de osteofitos (protuberancias óseas con forma de espuelas) que son la principal causa de desgaste o enfermedad degenerativa.
II	hiperplasia de los osteofitos y reducción articular cada vez más evidente.
III	El espacio articular entre las mesetas tibiales se reduce significativamente, el menisco comienza a verse afectado por el mecanismo de fricción y aplastamiento, los huesos comienzan a deformarse y los osteofitos continúan desarrollándose.
IV	Espacio articular reducido significativamente, osteofitos múltiples obvios, desgaste severo y deformidades óseas.

Tabla 1-1. Descripción escala de KL

Fuente: (drzezo, 2017)

En la siguiente Figura 1-3 se mostrará el espacio articular entre los dos extremos de la rodilla que son el fémur y la tibia por el cartílago dañado y los osteofitos que se encuentran en ella.



Figura 1-3: Presencia de osteofitos

Fuente: (Caleta, 2011)

1.2 Imagen Digital

1.2.1 ¿Qué es una imagen digital?

Una imagen digital es la representación discretizada a través de valores enteros sin signo generalmente de 8 bits de la luminosidad o el color de una escena y que son almacenados en un arreglo bidimensional (matriz), compuesta por filas y columnas que definen la ubicación de los píxeles dentro de una imagen (Viatela Ardila, 2001). Hay dos tipos de imágenes digitales:

- **Vectores o vectoriales:** Son imágenes compuestas por líneas llamadas vectores, que pueden ser rectas o curvas. La particularidad que encontramos en las imágenes vectoriales es la escalabilidad, es decir, cuando expandimos imágenes vectoriales, la imagen expandida no perderá calidad por ser una imagen plana (Ramon Alcalá J, 2008).
- **Mapa de bits o escala de grises:** Por lo general, lo obtenemos de las fotos y las imágenes de mapa de bits se componen de píxeles, por lo que sabemos que los píxeles son la unidad de medida más pequeña que tiene una imagen de mapa de bits (Patin aka, 2003)

1.2.2 Píxel

Un píxel es la unidad básica de representación dentro de una imagen digital, estos son responsables de almacenar información de color, como azul, rojo y verde. Si un píxel es uno o cero, la imagen es binaria, es decir representada únicamente en blanco y negro (Ramón Alcalá J, 2008).

1.2.3 Resolución de una imagen

La resolución de una imagen define la calidad de ésta, es decir, el número de píxeles en la imagen. Sabiendo que, si se almacenan más bits en estos píxeles, la imagen tendrá una calidad superior al mismo tiempo que aumentará su tamaño.

1.2.4 Escala de grises

Este es un sistema de gradiente ordenado con un rango discreto de valores de brillo entre blanco y negro. La escala suele tener 256 niveles y una sola dimensión, lo que hace que estas imágenes en escala de grises sean adecuadas para su procesamiento y uso (Ramón Alcalá J, 2008).

1.3 Preprocesamiento de imágenes médicas (rayos X)

Usualmente, debido a factores externos como el movimiento involuntario de los pacientes, el ruido atribuido a los equipos de adquisición de la imagen, la falta de contraste y la forma de almacenamiento, el preprocesamiento de imágenes de RX es considerado uno de los pasos más importantes para la mejora en la representación de las regiones de interés dentro de la imagen.

Por lo tanto, sin importar el tipo de imagen diagnóstica que se desee analizar (imágenes de rayos X (RX), imágenes de resonancia magnética (MRI) o tomografía computarizada (TC)), la etapa de preprocesamiento de imágenes médicas, contribuye a mejorar la calidad de la imagen y a resaltar la información de interés a través de procesos como el filtrado (Pandey, 2018) para que en la fase de segmentación y clasificación se logren resultados satisfactorios (Mori, 2010).

1.4 Ecuador de Histogramas

Esta técnica se utiliza para ajustar la intensidad y mejorar el contraste de la imagen (Thimmiaraja, 2014); para ello, ajusta la intensidad de la imagen para que la frecuencia de la imagen sea lo más parecida posible. En la ecuación (1) se puede ver la forma en la que se puede obtener dicho proceso.

$$P_n = \frac{\text{no. de pixeles con intensidad } n_k}{\text{total no. de pixeles } n}, \quad n = 0, 1, \dots, L - 1 \quad (1)$$

Donde:

- La frecuencia se expresa como una matriz de intensidades de píxeles que van de 0 a L-1, siendo L el número de posibles valores de intensidad.
- P representa el histograma de frecuencia

Considerando a:

g es la imagen de salida, en la que el histograma balanceado será

$$g_{i,j} = \text{floor}((L - 1)^x Pn) \quad (2)$$

- $g_{i,j}$ son coordenadas de los pixeles.
- *floor* Es una función de redondeo donde busca al número entero más pequeño. Es equivalente a la transformación de intensidades del pixel, k de $\square\square\square\square$ por la siguiente función.

La función $T(k)$ se llama ecualización o linealización de histograma. (Khalid, 2015)

$$T(k) = \text{floor}(L - 1^x pn), \quad k = 0, 1, \dots, L - 1 \quad (3)$$

$$n = 0$$

En el presente trabajo se utilizó Parallel Computing Toolbox en Matlab (histeq ()) para obtener un ecualizador de histograma por cada imagen de RX.

1.5 Filtro Wiener

Según (Sonka M, 2013), el filtro Wiener es más efectivo que el filtro mediano no solo en la región de baja frecuencia sino también en la región de alta frecuencia siendo eficaz para la supresión del ruido impulsivo y gaussiano (Sonka M, 2013).

Los filtros Wiener intentan priorizar el ruido combinando la restauración de imágenes a partir de la prioridad. A la restauración de la imagen se le da una estimación \hat{f}_b de la imagen original, que se puede obtener utilizando el mínimo error cuadrático medio.

$$e^2 = \varepsilon \left(f(i, j) - \hat{f}_b(i, j) \right)^2 \quad (4)$$

Donde:

- ε representa el operador medio.
- El valor estimado de \hat{f}_b es una combinación lineal del valor promedio de la imagen g , lo que indica que la imagen es ruidosa.
- El filtro de Wiener es una transformación de Fourier por HW.

Entonces \hat{f}_b se puede obtener como:

$$\hat{F}(u, v) = HW(u, v)G(u, v) \quad (5)$$

Dónde se obtiene:

$$H_w(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + \left[\frac{S_{vv}(u, v)}{S_{ff}(u, v)} \right]} \quad (6)$$

Donde:

- H es la función de transformación de la degradación.
- S_{vv} es la densidad espectral del ruido.
- S_{ff} es la densidad espectral de la imagen sin degradar (Haidekker, 2011).

En este trabajo se hizo uso de la función incluida dentro del Image Processing Toolbox (wiener2), la cual se implementó para disminuir el nivel de ruido en la imagen de RX.

1.6 Segmentación de Imágenes Médicas

1.6.1 Método de Otsu para la Segmentación de Imágenes

Método de Otsu: Nombrado en honor a su creador, Nobuyuki Otsu (1979), es un algoritmo de umbralización global el cual utiliza técnicas estadísticas calculando la varianza para la dispersión de los niveles de grises, encontrando el nivel óptimo de umbral para la separación entre el fondo y las regiones de interés de la imagen. Este método propone dos opciones para ello; La primera es minimizar la varianza para el fondo $\sigma_w^2(t)$, y la otra es maximizar la varianza entre clases usando la expresión $\sigma_b^2(t) = w_1(t) w_2(t) [\mu_1(t) - \mu_2(t)]^2$ donde μ_1 es la media de la clase i , con sus valores de intensidad (Martínez, 2013).

Por lo tanto se introduce la imagen en escala de grises con L niveles (0,1, 2, ..., L-1) y un número de píxeles con nivel i definido por n_i donde el número de pixeles es $N = n_0 + n_1 + n_2 + \dots + n_{L-1}$; Obteniendo el histograma de la imagen de la siguiente forma (López-Portilla Vigil, 2016):

$$p_i = \frac{n_i}{N}, \quad p_i \geq 0, \quad \sum_{i=0}^{L-1} p_i = 1 \quad (7)$$

Donde

- p_i es la probabilidad de que ocurra el nivel de intensidad i .

Ya que lo que se requiere es distinguir el fondo de las regiones de interés, tenemos que los píxeles se encuentran en las clases C_0 y C_1 por un umbral de nivel t , la clase C_0 pertenece a los píxeles de niveles $[0, \dots, t]$ y la clase C_1 a los píxeles con niveles $[t+1, \dots, L-1]$ (López-Portilla Vigil, 2016), teniendo que la probabilidad de que un píxel sea asignado a una de estas clases este dado por:

$$w_0 = P_{ri}(C_0) = \sum_{i=0}^t p_i = w(t) \quad (8)$$

$$w_1 = P_r(C_1) = \sum_{i=t}^{L-1} p_i = 1 - w(t) \quad (9)$$

Los valores medidos para las intensidades pertenecientes a las clases C_0 y C_1 son:

$$\mu_0 = \sum_{i=0}^t i P_r(i|C_0) = \sum_{i=0}^t \frac{ip_i}{w_0} = \frac{\mu(t)}{W(t)} \quad (10)$$

$$\mu_1 = \sum_{i=t+1}^{L-1} i p_r(i|C_1) = \sum_{i=t+1}^{L-1} \frac{ip_i}{w_1} = \frac{\mu(t)}{1-W(t)} \quad (11)$$

Donde

- $w(t) = \sum_{i=0}^t p_i$ es la suma de las intensidades.
- $\mu(t) = \sum_{i=0}^t ip_i$ es la intensidad promedio hasta el nivel t.
- $\mu(t) = \mu(L-1) = \sum_{i=0}^{L-1} ip_i$ es la intensidad media global para toda la imagen.

De lo anterior se cumplen las siguientes condiciones:

$$w_0\mu_0 + w_1\mu_1 = \mu_T, w_0 + w_1 = 1 \quad (12)$$

La varianza de las clases las dos clases C_0 y C_1 está dada por:

$$\sigma_0^2 = \sum_{i=0}^t (i - \mu_0)^2 P_r(i|C_0) = \sum_{i=0}^t \frac{(i - \mu_0)^2 p_i}{w_0} \quad (13)$$

$$\sigma_1^2 = \sum_{i=t+1}^{L-1} (i - \mu_1)^2 P_r(i|C_1) = \sum_{i=t+1}^{L-1} \frac{(i - \mu_1)^2 p_i}{w_1} \quad (14)$$

Luego de evaluar la varianza entre las clases, se evalúa la viabilidad del umbral (t), donde se toman los tamaños de criterio de diferenciación entre cada clase empleada en el análisis como se muestra en la ecuación (15).

$$\sigma_B^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2 \quad (15)$$

Ya para encontrar el umbral ideal t^* que maximiza σ_B^2 se seleccionan los valores de t que están entre (0 a L-1) con el uso de las cantidades acumuladas $\square(\square) = \sum_{\square=0}^{\square} \square_{\square}$ y $\square(\square) = \sum_{\square=0}^{\square} \square_{\square}$ o usando las ecuaciones (8), (9), (10) y (11):

$$\sigma_B^2(t) = \frac{[\mu_T \omega(t) - \mu(t)]^2}{\omega(t)[1 - \omega(t)]} \quad (16)$$

Por lo tanto, el umbral ideal t^* es:

$$\sigma_B^2(t^*) = \max_{0 \leq t \leq L-1} |\sigma_B^2(t)| \quad (17)$$

Para visualizar mejor su función del método de Otsu se utilizó el comando “graythresh” y se aplicó un umbral-binarización con el comando “im2bw ()”, esto se hace con el fin de umbralizar y binarizar todas las imágenes que se van a utilizar de cada grado de OA.

1.7 Extracción de Características

En todo proceso de aprendizaje automático es primordial encontrar una forma de representación de la información que permita la codificación de los píxeles de una imagen en una cantidad que capture información mucho más significativa que los datos crudos sin procesar. Se hace importante entonces, encontrar una buena manera de representar los objetos o regiones de interés como cantidades (números), que resalten esa información subyacente. Esto generalmente significa escribir un código personalizado para calcular dichas características (Guyon I, 2008).

Es posible calcular automáticamente algunas características que son más significativas que los píxeles. Los bordes entre regiones de color, a menudo son una buena característica y se pueden calcular utilizando filtros espaciales. Pero sin lugar a duda hay muchas metodologías para obtenerlas en el estado del arte.

En esta etapa se hace una extracción de la información midiendo las propiedades de las regiones de la imagen. Este método se utiliza ya que funciona para el procesamiento morfológico de imágenes y también puede medir las propiedades de las regiones de la imagen.

Para este trabajo de grado se extrajeron algunas características como el área de la imagen de rodilla, perímetro y la separación de los centroides (Entre el Fémur y la Tibia) de cada una de las imágenes de rayos x contenidas en las bases de datos con la función "regionprops ()" de Matlab (Matlab, MathWorks, 2020).

1.8 Máquinas de Vectores de Soporte (Support Vector Machine (SVM))

La máquina de soporte vectorial o SVM por su nombre en inglés (Support Vector Machine), es uno de los clasificadores más versátiles, populares y potentes utilizados dentro del aprendizaje de máquina supervisada. Este algoritmo fue introducido por Corinna Cortes y Vladimir Vapnik (C. Cortes and V. Vapnik, 1995) y desde entonces se ha utilizado con éxito dentro de una variedad de campos y aplicaciones como detección de rostros (C. Wang, 2011), detección de intrusos (Agarap FA, 2018), clasificación de correo electrónico, artículos de noticias (Xu K, 2014), páginas web, etc; en general en cualquier problema donde se requieran procesos de clasificación o regresión a través de un enfoque eficaz y sistemático.




Figura 1-4: Hiperplano de separación

Fuente: (Carmona Suarez, 2016)

El propósito de este algoritmo es generar un hiperplano que permita discriminar las muestras en el espacio de características en dos regiones diferentes (Dhabhai. A, 2016). Dicho hiperplano o frontera en el caso ideal de un espacio de dos dimensiones, puede ser representado a través de una línea, como se observa en la figura 1-4. Una particularidad interesante aportada por estos datos ideales y linealmente separables (Yin-Wen C, 2008) es

que va a ser posible generar variedad de líneas (hiperplanos) que permitan categorizar el espacio de características en dos regiones y con diferentes ubicaciones (Concha, 2011), tal como se ve en la figura 1-5, siendo entonces obvio que no existe un único modelo para separar este espacio de características.




Figura 1-5: Casos de hiperplano separación

Fuente: (Carmona Suarez, 2016)

Una particularidad específica de las SVM es el uso de vectores de soporte que no son más que cierta cantidad de muestras de ambas clases del conjunto de entrenamiento y que son seleccionados de acuerdo con una medida de distancia máxima entre ellos y el hiperplano, conocida como margen. El uso de dichos vectores genera cierto nivel de robustez haciéndolo un modelo más generalizante, evitando así el sobreajuste (overfitting). Esta condición hace entonces que se prefiera el hiperplano que maximice la región comprendida entre dichos vectores y el hiperplano tal como se muestra en la figura 1-6. Si esta condición no se cumple el modelo generado va a tener un margen más estrecho y por lo consiguiente un margen de seguridad menor cuando se clasifiquen las muestras más cercanas a la frontera de decisión (Bradley J. Erickson, 2017).




Figura 1-6: Componentes de SVM

Fuente: (Matlab, MathWorks, 2020)

Se debe tener en cuenta que los datos de entrada para todos los casos no siempre serán linealmente separables, por lo que se tiene la opción de utilizar un clasificador no lineal el cual consiste en modificar los datos mencionados anteriormente como se visualiza en la Figura 1-7, a un espacio de características de mayor dimensión, donde podrán separarse por el hiperplano.




Figura 1-7: Datos no separables linealmente.

Fuente: (Román V, 2019)

Al tener datos que no son linealmente separables, se debe hacer un mapeo o transformación del espacio a través del uso de funciones Kernel, que como se aprecia en la figura 1-8, tiene como objetivo mapear los datos a un espacio de alta dimensionalidad para poder separarlos más fácilmente. Se debe tener en cuenta el tipo de Kernel y los valores de sus parámetros

para así obtener los diferentes límites de decisión. En las ecuaciones (18), (19) y (20), se nombran algunos de los Kernel más destacados.

- Kernel Lineal: El Kernel lineal es utilizado para proporcionar clasificadores de dos clases, siempre y cuando los valores de clases se pueden separar, esto se puede ver mediante una superficie de decisión lineal (Amat Rodrigo J, 2017).

$$K(x, x') = x^T \cdot x' \quad (18)$$

- Kernel Polinomial: Utilizado comúnmente para el procesamiento de imágenes (Léon, 2016), el Kernel Polinomial mapea datos de entrada determinando similitudes en los vectores, en búsqueda de combinaciones (características de interacción) de estos datos. Transformando los datos de características de las clases en un espacio con un mayor número de dimensiones para trazar la superficie de decisión y lograr la clasificación de los datos con un alto porcentaje de precisión (Amat Rodrigo J, 2017).

$$K(x, x') = (x^T \cdot x' + c)^d \quad (19)$$

- Kernel de Base Radial (RBF): Este es utilizado para problemas de la clasificación de datos no lineales en el espacio de dimension inicial, y se llevan estos datos a un espacio de mayor dimension para poder así lograr una clasificación mas eficiente. Por lo tanto, este metodo es uno de los mas utilizados (S. Han, 2014).

$$K(\vec{x}, \vec{l}^i) = e^{-\frac{\|\vec{x} - \vec{l}^i\|^2}{2\sigma^2}} \quad (20)$$




Figura 1-8: Aplicación de la función Kernel a un grupo de datos

Fuente: (Farias Concha NM, 2011)

Además de las funciones Kernel, también, es utilizado un método llamado el truco Kernel (López Pineda G, 2017) (ver Figura 1-9). Este truco consiste en hallar una nueva dimensión, para que esta pueda separarse en las dos clases, se aplica para la solución de problemas de inseparabilidad lineal. El cual permite utilizar cualquier función de Kernel que permita identificar la similitud de los datos en dimensiones más altas, sin incrementar significativamente el costo computacional.




Figura 1-9: Truco Kernel

Fuente: (IArtificial.net)

Como el truco de Kernel nos permite operar en un espacio de características original sin calcular las coordenadas de los datos en un espacio dimensional superior (López Pineda G, 2017) este está definido por:

$$K(x_i, x_j) = x_i \cdot x_j = x_i^T \cdot x_j \quad (21)$$

Si cada punto de datos se asigna a un espacio de alta dimensión:

$$\varphi: x \rightarrow \varphi(x) \quad (22)$$

y el producto escalar se convierte en:

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j) \quad (23)$$

Para estos casos también se utiliza la margen suave (soft margin) (Hertzmann A, 2015), que esta permite que la SVM tenga un número pequeño de errores, debido a esto puede

mantener un margen amplia, para que los puntos que no se han clasificado correctamente, lo hagan.

Cuando se tienen dos clases que no son linealmente separables, se tiene la condición para el hiperplano óptimo (Wang R, 2016) como se muestra en la ecuación (23):

$$y_i(x_i^T w + b) \geq 1 - \xi_i, \quad (i = 1, \dots, m) \quad (24)$$

El error mínimo $\xi_i \geq 0$, debe minimizarse $\|\xi\|$, para obtener la función objetivo

$$\text{Minimizar} \quad w^T w + C \sum_{i=1}^m \xi_i^k \quad (25)$$

$$\text{Sujeto a} \quad y_i(x_i^T w + b) \geq 1 - \xi_i, \quad y \quad \xi_i \geq 0; \quad (i = 1, \dots, m) \quad (26)$$

Donde:

- C es un parámetro de regularización, que esta tiende a sobre ajustarse a los datos de entrenamiento.
- c este parámetro enfatiza en el margen y así ignora los valores diferentes en los datos de entrenamiento.

En la Figura 1-9, se muestra la clasificación que hace la margen suave.




Figura 1-10: Clasificación de margen suave

Fuente: (MLMath.io, 2013)

Teniendo ya una idea de lo que es una SVM, en los siguientes párrafos se hará la formulación matemática que permita reflejar de manera más formal los conceptos involucrados en la definición planeada previamente.

Para el algoritmo SVM, debe tener entradas y salidas para poder solucionar el problema de optimización. Por esto, se tiene un vector

$$\vec{X}_i = X_{i1}, X_{i2}, \dots, X_{in} \quad (27)$$

Tenemos \square_{\square} que esta es la clase a la que pertenece cada observación. Lo que se hace es que si estamos en la clase 1 se pondrá un 1 y si está en la clase 2 se pondrá un -1.

$$y_i = \{1, \quad \text{si } \vec{X}_i \text{ en clase 1} \quad -1, \quad \text{si } \vec{X}_i \text{ en clase 2} \quad (28)$$

Para la salida se tiene $\square\square\square\square$, que esta da la superficie de ajuste, esta superficie se encuentra en el medio de la margen.

$$\vec{W} = [w_1, w_2, \dots, w_n] \quad (29)$$

El propósito de la clasificación SVM es construir una función de clasificación lineal que herede la relación de dependencia entre la salida \square_{\square} y la entrada \square_{\square} , para obtener una función de la siguiente forma (Gavrilov Z) (MLMath.io, 2019):

$$f(x) = w^T x + b \quad (30)$$

1.9 Matriz de Confusión

La matriz de confusión es una herramienta ampliamente usada para evaluar el desempeño de cualquier algoritmo de clasificación dentro del aprendizaje supervisado. Esta métrica se utiliza para encontrar la precisión y la exactitud del modelo de clasificación cuya la salida contenga dos o más clases (García Balboa, 2018)

En la tabla 1-2 se observa la matriz de confusión para evaluar un modelo de dos clases. Como se evidencia dicha tabla contiene a nivel de filas las observaciones con sus etiquetas reales y a nivel de columnas las predicciones obtenidas por el clasificador previamente entrenado y para el cual se desea medir el desempeño. Cada cuadrante de la tabla tiene su asignación siendo VP la cantidad de datos verdaderos positivos que se lograron clasificar

correctamente, VN es la cantidad de datos verdaderos negativos o de la otra clase que se lograron clasificar correctamente, FN es la cantidad de datos positivos que se clasificaron incorrectamente como datos negativos y FP es la cantidad de datos negativos que se clasificaron incorrectamente como datos positivos. Cabe resaltar que este análisis se debe realizar con datos que el clasificador no haya visto durante el entrenamiento, que se conocen como datos de prueba (test). la idea es que las predicciones y las observaciones coincidan, es decir que todas las muestras se ubiquen en la diagonal de la tabla (Pizzi, 2006).

	Predicciones	
Observaciones	Positivos	Negativos
Positivos	Verdaderos Positivos (VP)	Falsos Negativos (FN)
Negativos	Falsos Positivos (FP)	Verdaderos Negativos (VN)

Tabla 1-2. Matriz de confusión

Fuente: Elaboración propia

Una vez obtenidos los datos para cada cuadrante existen una serie de cálculos que se pueden implementar con la matriz para medir diferentes parámetros. Por ejemplo, la función para hallar la exactitud del porcentaje de los datos está dada por:

$$Ex = \frac{VP + VN}{Total} \quad (31)$$

Para hallar la tasa de error, que este es el porcentaje de la data que hace la clasificación como si fuese del grado que no corresponde. Por ejemplo: Clasifica a una imagen de grado I como una imagen de grado II.

$$TE = \frac{FP + FN}{Total} \quad (32)$$

El porcentaje de sensibilidad que logra clasificar cuando la clase de datos es positiva.

$$S = \frac{VP}{\textit{Total de datos Positivos}} \quad (33)$$

El porcentaje de especificidad que logra clasificar cuando la clase de datos es negativa.

$$Es = \frac{VN}{\textit{Total de datos Negativos}} \quad (34)$$

2 Metodología

En esta sección del documento se presenta la metodología empleada para desarrollar el sistema de clasificación de los grados I y II de OA de rodilla utilizando SVM, que involucra procesos como la recolección de imágenes, construcción de la base de datos, tareas de mejora usando técnicas de procesamiento digital de imágenes conocidas dentro de este contexto como preprocesamiento, codificación de la información más relevante a través de la extracción de características y la generación del modelo de clasificación haciendo uso de las máquinas de soporte vectorial y los detalles de la misma.

En la Figura 2-1 se presenta el diagrama de bloques de las etapas principales del sistema propuesto a través de esta implementación, cuyo método de clasificación se basa en una máquina de vectores de soporte (SVM) para hipotetizar el grado I o II de osteoartritis en una imagen de rayos-x de rodilla determinada. El proceso de estimación de dichos grados procede de la siguiente manera: dada una imagen radiológica de rodilla perteneciente a los grados I o II (no se tienen en cuenta los otros tres grados, así que se debe evitar el uso de imágenes de los grados 0-III- IV), se realiza un proceso extracción de las regiones de interés de tamaño 158x209 pixeles utilizando las funciones de Matlab. Es importante señalar que todas las muestras fueron sometidas a un proceso de transformación a escala de grises para poder utilizar las técnicas de segmentación propuestas, por lo tanto, dicha transformación también es necesaria durante la estimación. Entonces para cada región de interés obtenida a partir de la base de datos, se realiza un proceso de extracción de características informativas y luego estas características se introducen en el clasificador SVM que ha sido entrenado con el 70% (23 imágenes de grado I y 38 imágenes de grado II) de las muestras de imágenes de grado I y grado II destinadas para el entrenamiento, finalmente el clasificador entrega las estimaciones a manera de etiquetas.

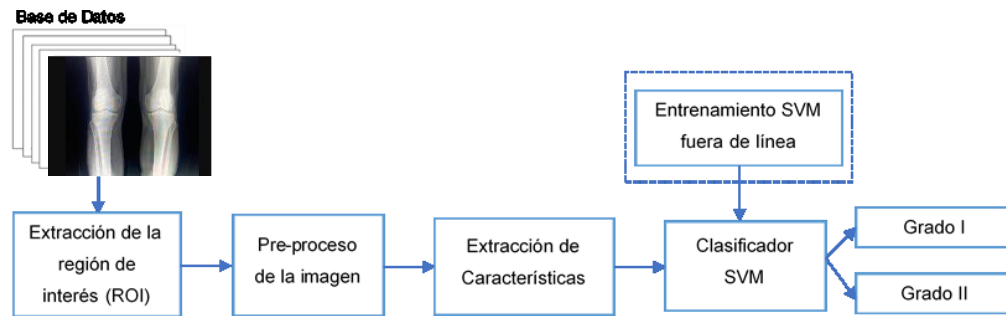


Figura 2-1: Diagrama de bloques para la segmentación de la imagen de Rayos X

Fuente: Elaboración propia

Ahora, se presentan las particularidades relacionadas con cada una de las etapas involucradas en el sistema de la figura 2-1. Comenzando por describir las bases de datos involucradas en el entrenamiento y validación de este.

2.1 Bases de datos utilizadas

Como primera medida, teniendo en cuenta que uno de los objetivos específicos de este trabajo era determinar un banco de radiografías de pacientes con diagnóstico de osteoartritis de rodilla grado I y II, solicitada por medio de un derecho de petición dirigido al departamento de investigación de la clínica Medilaser de Neiva, quienes exigieron como requisito un estado del arte, además de, una justificación para la solicitud de estas.

Luego de la aceptación de la solicitud por parte de la entidad, el conjunto de imágenes solicitadas fue entregado por la clínica en un sistema de almacenamiento en formato DVD, etiquetadas con su respectivo grado de osteoartritis, previa selección por parte de un especialista en Traumatología de la misma entidad, quien garantiza la correcta asignación de cada grado de Osteoartritis de rodilla. De esta forma se obtuvieron 86 imágenes multicanal (RGB) de 24 bits, en formato *PNG con dimensiones de 1920 x 1080 pixeles donde 32 de estas imágenes están etiquetadas como grado I y 54 imágenes como grado II.



Figura 2-2 Imagen Original de Rayos x

Fuente: Clínica Medilaser de Neiva

Se puede apreciar en la Figura 2-2 una imagen escalada del conjunto de datos proporcionado por la clínica, en esta se evidencia que no solo poseen una gran cantidad de píxeles, sino que también se visualizan partes como el fémur y la tibia que para este estudio es irrelevante. Por ello se optó por extraer la región de interés (ROI) que compete únicamente al segmento de la rodilla. También dado que la imagen tenía una profundidad de 24 (bits), se procedió a transformar toda la base de datos a escala de grises.

Finalmente, en la Figura 2-3, se observa una muestra de 38 imágenes de grado I de OA de rodilla utilizadas para el banco de imágenes propio. Luego del proceso de transformación a escala de grises y extracción de región de interés, donde se pasó de tener dimensiones 1920 x 1080 a 158x209 píxeles.




Figura 2-3: Muestras de imágenes de grado I de la base de datos propia.

Fuente: Elaboración propia

En la Figura 2-4, se observa una muestra de 55 imágenes de grado II de OA de rodilla utilizadas para el banco de imágenes propia, luego del proceso de transformación a escala de grises y extracción de región de interés, donde se pasó de tener dimensiones 1920 x 1080 a 158x209 pixeles.



Figura 2-4: Muestras de imágenes de grado II de la base de datos propia
Fuente: Elaboración propia

Como se evidencia, las imágenes obtenidas por la Clínica Medilaser de Neiva fueron muy pocas, por tanto, surgió la necesidad de contar con otra base de datos, llamada Knee Osteoarthritis Severity Grading Dataset (Chen, 2018). Al visualizar esta base de datos, se pudo observar que venía distribuida en los 4 grados de KL, y cada uno de los grados tiene una división de imágenes de rayos X con diagnóstico de OA de rodilla para el entrenamiento y otra para la validación, cada una de las imágenes almacenadas en formato *.PNG de 24 bits de profundidad, con dimensiones de 224x224 pixeles. La carpeta total con los 4 grados de KL tenía un peso de 7GB. Teniendo en cuenta, que para esta investigación solo se

necesitaba imágenes de grado I y grado II, por lo tanto, los grados 0, III y IV fueron desestimados. Utilizando un total de 1046 imágenes de grado I y 1516 imágenes de grado II.

Al igual que con la base de datos propia, se hizo una transformación a escala de grises y se hizo extracción de la región de interés.

En la Figura 2-5, se muestran las imágenes de grado I con diagnóstico de OA de rodilla, obtenidas del banco de imágenes ya existente (Knee Osteoarthritis Severity Grading Dataset) (Chen, 2018).




Figura 2-5: Muestras de imágenes de grado I de la base de datos (Knee Osteoarthritis Severity Grading Dataset)

Fuente: Elaboración propia

En la Figura 2-6, se muestran las imágenes de grado II con diagnóstico de OA de rodilla, obtenidas del banco de imágenes ya existente (Knee Osteoarthritis Severity Grading Dataset) (Chen, 2018).

- 1516 imágenes de Rayos X de rodilla con diagnóstico de Osteoartritis grado II.



Figura 2-6: Muestra de imágenes grado II de la base de datos (Knee Osteoarthritis Severity Grading Dataset).

Fuente: Elaboración propia

2.2 Fase de Preprocesamiento de la base de datos

Debido a que las imágenes siempre contienen cierto nivel de ruido debido a movimiento voluntario o involuntario del paciente; superposición de huesos, entre otros, se hizo necesario implementar una etapa de preprocesamiento para así mejorar algunos aspectos como el contraste, cuya finalidad es agudizar la imagen y corregir los defectos de cada una de las imágenes de rayos X (Ramamurthy, 1995), (Mori, 2010).

En aplicaciones médicas, el preprocesamiento de imágenes se considera un paso clave en la creación de un sistema de diagnóstico. De esta forma, el sistema puede servir como una segunda opinión para ayudar a los especialistas. Ya se trate de Rayos X (RX), u otros métodos de toma de imágenes (Imágenes de Resonancia Magnética o Tomografía computarizada), una de las etapas clave de las imágenes médicas es la etapa de preprocesamiento.

La investigación desarrollada nos muestra que la calidad de las imágenes de rayos X se puede mejorar utilizando el método de preprocesamiento de imágenes, que puede eliminar los cambios bruscos en la vecindad de píxeles. Basándonos en la aplicación de dos procedimientos los cuales son: El Ecuilizador de Histogramas (Cheng-Jin Du, 2008) y el Filtro Wiener (López Díaz, 2018), con los que se ha obtenido resultados satisfactorios en la visualización de las zonas de interés en imágenes de Rayos x.

En la Figura 2-7 que se visualiza a continuación, se muestran los pasos que se harán al momento del preprocesamiento.

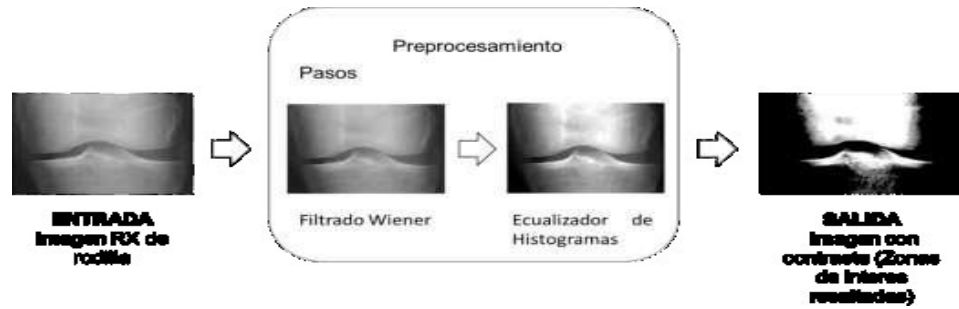


Figura 2-7: Diagrama de bloques de pasos para el Preprocesamiento de la imagen de Rayos X de rodilla

Fuente: Elaboración propia

Para la presente investigación lo que se hizo fue pasar cada una de las imágenes del banco a escala de grises. En la Figura 2-8, se muestra el ROI que se hizo para que las imágenes quedarán de un mismo tamaño en cuál fue 158x209 píxeles, esto se hizo al ver que las imágenes tenían un tamaño irregular, y facilitó la extracción de las características de cada una de las imágenes.




Figura 2-8: Se muestra la imagen de entrada RGB original y a la salida se muestra la región de interés (ROI) y en escala de grises

Fuente: Elaboración propia

En la Figura 2-9 se muestra los pasos que se tuvieron en cuenta en esta fase.

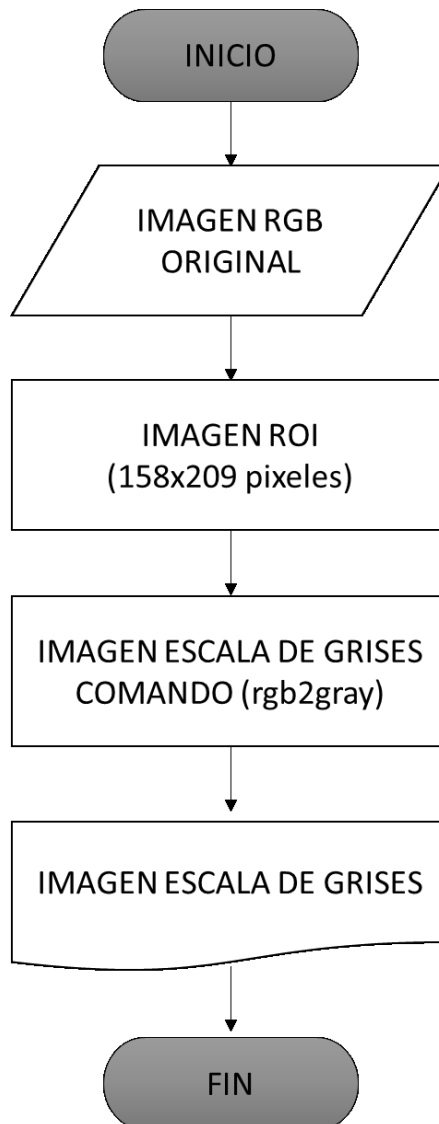


Figura 2-9: Imagen de entrada RGB original y a la salida se muestra en escala de grises

Fuente: Elaboración propia

A continuación, se explicará cada uno de los pasos que se hizo para el procesamiento de las imágenes.

2.3 Implementación del Filtro Wiener (Wiener Filter)

Este método se considera uno de los métodos de preprocesamiento más completos para eliminar el ruido en las imágenes de rayos x, debido a que es diferente de otros métodos, recibe dos parámetros como entrada: la imagen de entrada y la imagen guiada a convertir; utiliza métodos estadísticos para reducir el ruido adicional en la señal de observación para que la salida del filtro esté lo más cerca posible de la señal deseada sin ruido (López Díaz, 2018).

Para esta investigación se tomó como entrada la imagen de rayos x ajustada en escala de grises con el tamaño del Kernel (la utilidad de Kernel se basa en el análisis de datos y radica en la representación de la información) que se va a utilizar; siendo un Kernel 2 x 2, se hace paso del filtrado Wiener para eliminar el ruido, hablando así de un filtro adaptativo el cual consiste en una forma binaria utilizada para cuantificar y codificar datos de entrada, salida y filtrado. Dado que se desconocen las características estadísticas de la señal a filtrar, o cuando la señal es conocida, pero es una señal variable en el tiempo, es necesario hacer que los coeficientes del filtro no sean fijos sino variables.

Al implementar el filtro Wiener, se pudo visualizar que se suavizó la imagen, pero también se aplicó el comando `"bwareaopen ()"`, que este se utilizó para rellenar los agujeros que aún tenía la imagen. El procedimiento nombrado anteriormente se muestra en la Figura 2-10.




Figura 2-10: Imagen antes y después de ser tratada con el Filtro Wiener

Fuente: Elaboración propia

En la Figura 2-11 se visualiza los pasos que se siguieron para la implementación del Filtro Wiener.

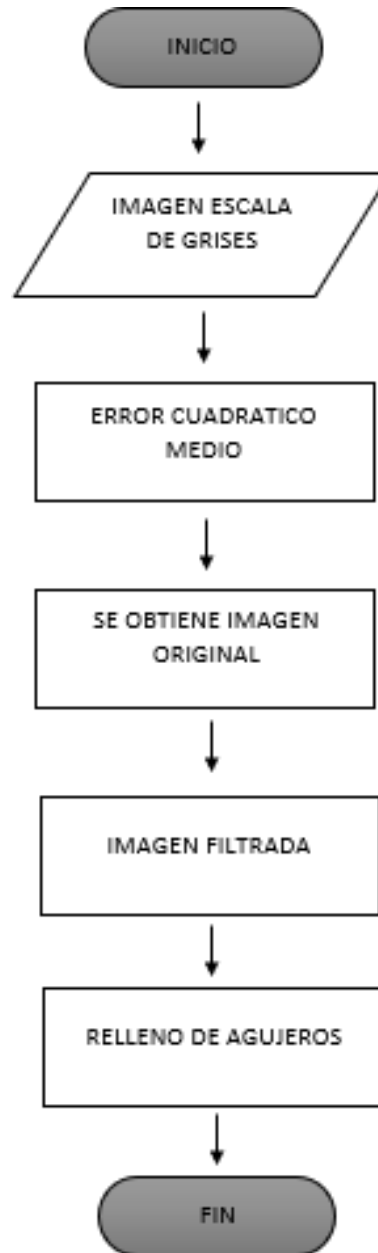


Figura 2-11: Proceso para el Filtrado de Wiener

Fuente: Elaboración propia

2.4 Implementación del Ecuador de Histogramas (Histogram Equalization)

El histograma de la imagen de entrada nos muestra que hay una gran concentración de los píxeles de baja intensidad, al observar la imagen es claro que estos píxeles corresponden a la parte oscura de la imagen. El análisis del histograma también permite ver el efecto que tienen las transformaciones de intensidad, cuando se ecualiza la imagen con el comando "histeq ()" en Matlab, se puede ver un cambio tanto en la imagen de salida como en su histograma, que este corresponde a ocupar todo el rango dinámico y se muestra cuando el histograma se expande desde el gris mínimo al gris máximo. Esto se hace para mostrar mejor la imagen para la extracción de características como se muestra en la Figura 2-12.

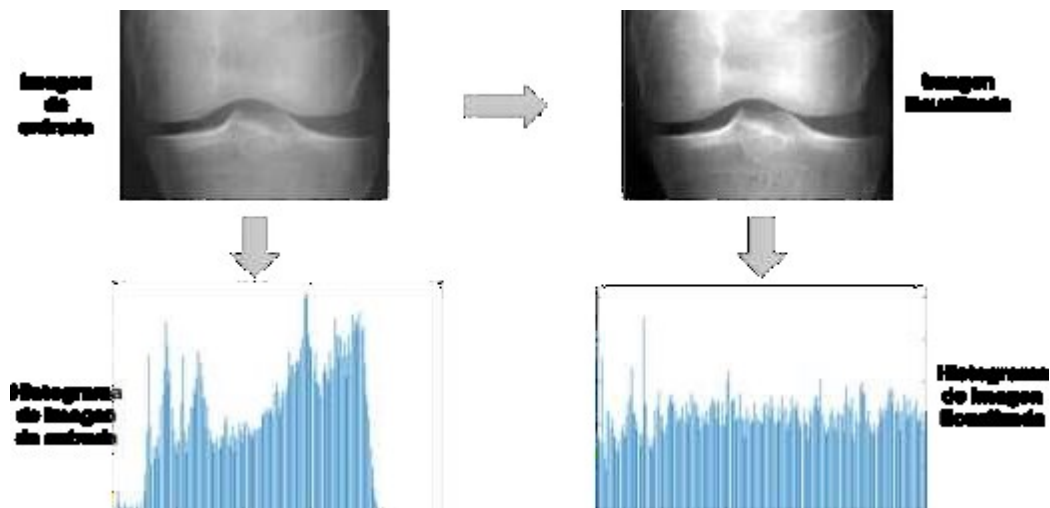


Figura 2-12: Ecuación de Histograma

Fuente: Elaboración propia

En la Figura 2-13 se muestra los pasos para la ecualización del Histograma, el cual inicia con una imagen filtrada, después se calcula el histograma con el comando "histeq ()" y se balancea con el comando "imadjust ()" en Matlab, para que este histograma generado tenga

los niveles de intensidad de gris correctos, al finalizar se realiza un ajuste de contraste para la segmentación de cada una de las imágenes.

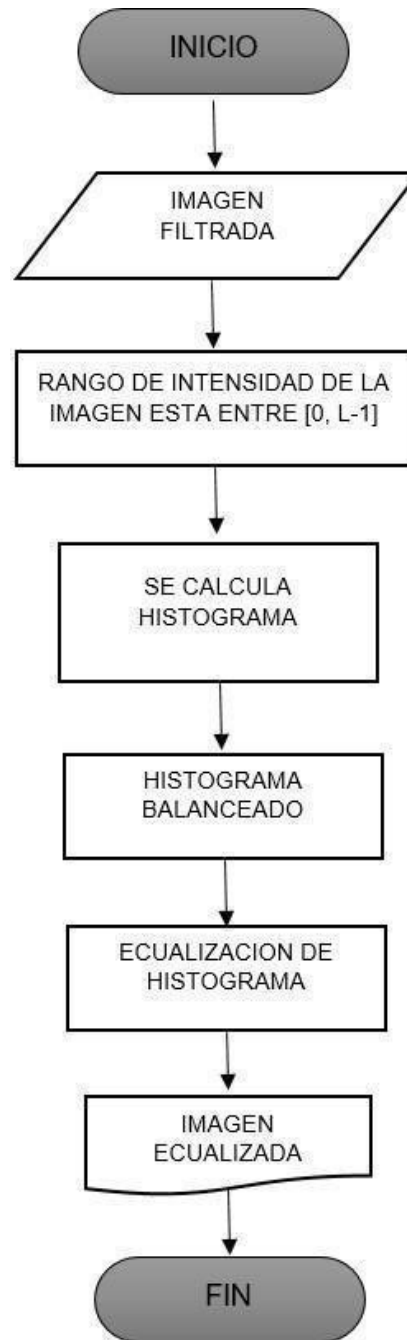


Figura 2-13: Pasos para la Ecualización de Histograma

Fuente: Elaboración propia

2.5 Fase de Segmentación de la base de datos

La observación digital de imágenes médicas juega un papel importante en la decisión del especialista sobre el área anatómica de la zona evaluada. Por tanto, la etapa de segmentación es crucial en este proceso.

En este trabajo de investigación, la etapa de segmentación es muy importante para la visualización del área de interés en la imagen de rayos X de la rodilla; estas áreas son la tibia y el fémur. Además de estas áreas, la zona cercana a esta zona también puede verse afectada por la diferencia (distancia) entre estas dos áreas.

Como la segmentación del presente trabajo se realizó por el método de Otsu en Matlab, lo que primero que se hace es generar el nivel de Otsu con el comando `"graythresh ()"`, luego se binariza la imagen con el comando `"im2bw ()"` y a este se le aplica el umbral (nivel de Otsu) que se calculó anteriormente, después de esto se rellenan los agujeros ya que las regiones internas a las regiones de interés no tengan este tipo de falencia, al finalizar se hace un opening para ensanchar la imagen con el comando `"bwareaopen ()"`, y así generar una imagen segmentada. Este proceso se muestra en la Figura 2-14.



Figura 2-14: Proceso para la segmentación de las imágenes

Fuente: Elaboración propia

En la Figura 2-15 se visualiza los pasos que se realizaron para la Segmentación de las imágenes.

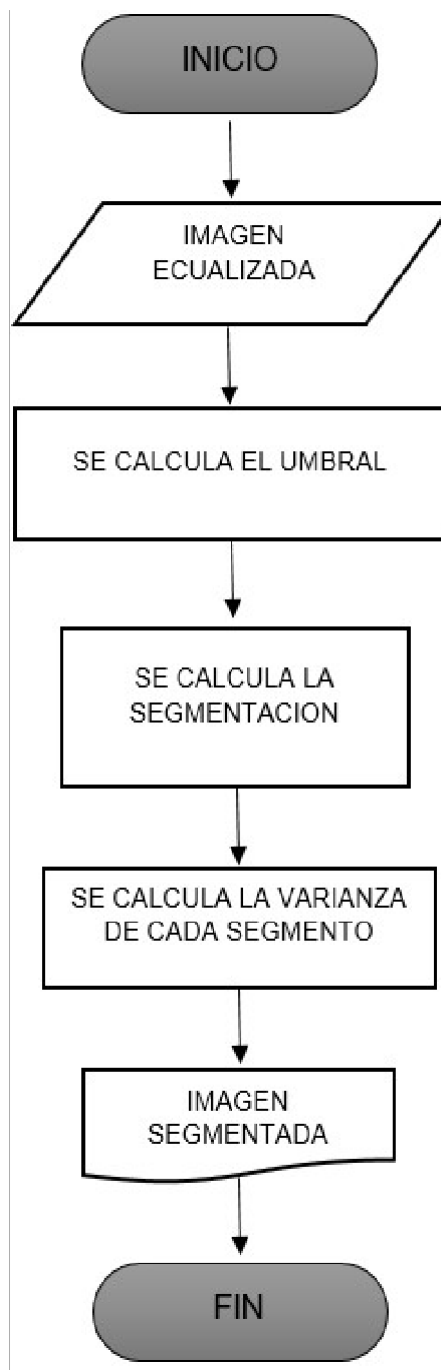


Figura 2-15: Pasos para la segmentación de las imágenes

Fuente: Elaboración propia

2.6 Fase de Extracción de Características de la base de datos

En el presente trabajo de investigación, se obtuvieron tres regiones de interés como se observa en la Figura 2-16 (la parte superior, la parte inferior y el fondo de la imagen) a partir de la imagen de rayos X. Los atributos del área se encuentran de forma independiente.



Figura 2-16: Imagen con las regiones de interés

Fuente: Elaboración propia

Teniendo como entrada la imagen segmentada, luego, se añade el comando *"bwlabel ()"* en Matlab y este lo que hace es etiquetar las regiones de interés de cada imagen de RX, donde se extraen 5 características como: centroide, área, perímetro, extensión y orientación. Utilizando el comando *"regionprops ()"*, como este comando lo que hace es extraer una estructura de datos, entonces, se extrae una estructura de datos de cada característica, al finalizar este proceso, se genera el vector de características. Debido lo anterior, se tienen dos opciones, la primera cuando el número de regiones es igual a uno, esto sucede al encontrar que algunas imágenes de grado II que se visualizan con un estrechamiento articular más grande que las imágenes de grado I, la segunda opción se aplica para cuando

las regiones de interés son dos o mayor a este, extrayendo el centroide de la región uno y la región dos (fémur y tibia) con el comando "improfile ()" y se traza la recta entre el centroide de cada una de las regiones, el comando anteriormente nombrado, se torna un vector al cual llamamos (c), que este vector, son todos los pixeles por donde pasa esta línea, por lo tanto, se va a obtener pixeles unos y ceros, teniendo en cuenta que se debe contar los pixeles ceros para formar esta recta. La distancia entre ellos se halla sumando estos ceros, luego, se calcula el área total de la región de interés (la parte superior e inferior), así mismo, se halla el perímetro total, la extensión y orientación, generando el vector de características para este paso.

De las 5 características mencionadas anteriormente solo se utilizó el centroide de las regiones de interés, en el cual se calculó la distancia entre estos, ya que esta proporcionaba una mayor diferencia entre cada uno de los grados de OA utilizados. En la Figura 2-17, se observan los dos centroides y la distancia de separación entre ellos.

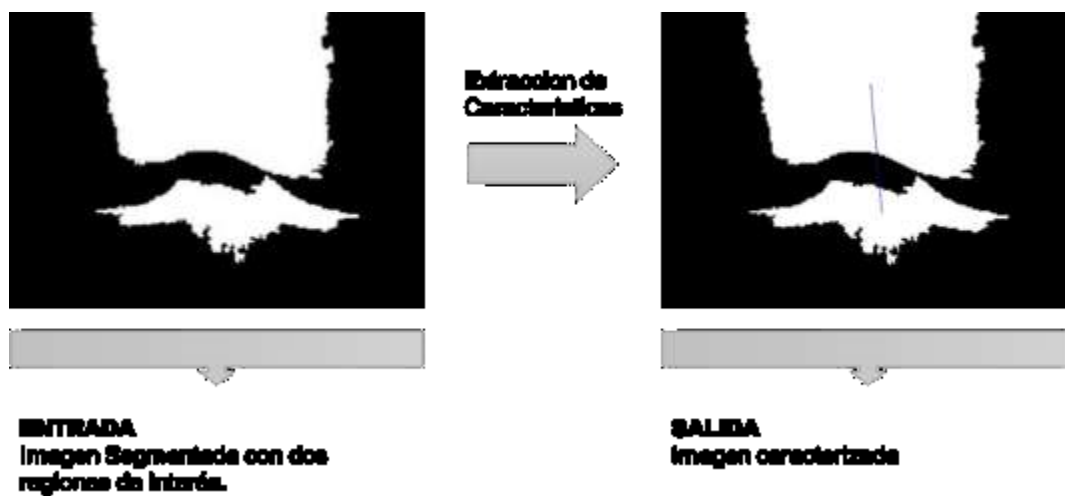


Figura 2-17: Proceso de extracción de características con dos regiones de interés

Fuente: Elaboración propia

2.7 Fase de Clasificación de la SVM

Para esta fase del estudio realizado, se utilizó el método de Máquinas de Soporte de Vectores (C. Cortes and V. Vapnik, 1995); como clasificador binario, considerando que este cuenta con dos clases:

- Imágenes de Rayos X con Osteoartritis de rodilla grado I; Indicadas con el valor '1'
- Imágenes de Rayos X con Osteoartritis de rodilla grado II; Indicadas con el valor '2'

En la fase de entrenamiento se utilizaron 23 radiografías de rodilla con diagnóstico de Osteoartritis grado I, y 38 radiografías con diagnóstico en Osteoartritis de rodilla grado II. Estos dos grados fueron tratados y segmentados anticipadamente.

Se utilizaron 9 imágenes de RX de rodilla de grado I para la evaluación y 16 imágenes de RX de rodilla de grado II. Teniendo en cuenta la principal característica escogida, se define un Kernel Polinomial en orden 3 para la base de datos propia, este se utilizó debido a que este modelo genera límites de decisión no lineales y así transforma los datos de características de las clases en un espacio con un mayor número de dimensiones para alcanzar la clasificación de los datos con un alto porcentaje de precisión, además se utilizó un Kernel de Base Radial (RBF), en vista que este modelo es usado para encontrar clasificaciones no lineales creando un espacio de mayor dimensión, para poder así lograr una clasificación más eficiente, y finaliza estandarizando los datos. Para la base de datos (Knee Osteoarthritis Severity Grading Dataset), se utilizó un Kernel Lineal, el uso de este Kernel se debió a que se visualizó una diferencia mayor entre las imágenes de grado I y grado II de la base de datos nombrada anteriormente, queriendo conocer así la eficiencia de este Kernel al tener una base de datos con una mayor cantidad de imágenes.

En la Figura 2-18 se muestra el paso a paso de la fase Clasificación de la SVM:

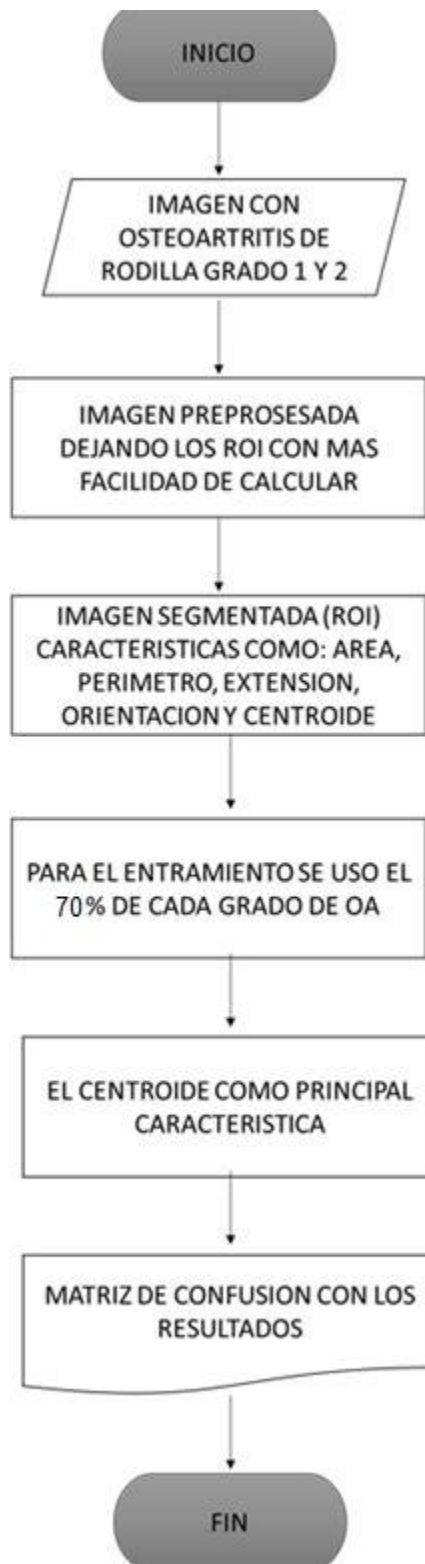


Figura 2-18: Clasificación SVM

Fuente: Elaboración propia

En la Figura 2-19, se muestra la característica que se utilizara que es la distancia entre los centroides, y se indica los siguientes pasos que dan como resultado la evaluación del clasificador SVM.

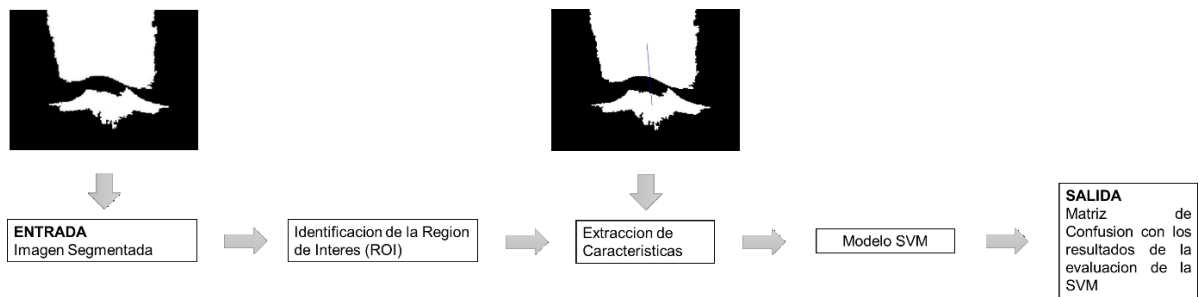


Figura 2-19: Pasos para la evaluación de la SVM.

Fuente: Elaboración propia

Para el entrenamiento de un clasificador SVM en Matlab, se realiza una validación cruzada con el comando `fitcsvm`. Sabiendo que se utilizó el 30% de las imágenes de cada grado I y 2 de OA de rodilla. El código implementado para el entrenamiento de la SVM es:

$$M = \text{fitcsvm}(X_train(:,A), Y_train, 'KernelFunction', 'polynomial', \dots$$

$$'PolynomialOrder', 3, 'Standardize', true); 'ClassNames', {'Grado1', 'Grado2'})$$

Donde:

- X_train , cada fila es una observación y cada columna es un predictor.
- Y_train es un vector lógico de caracteres.
- `KernelFunction`, el valor `'polynomial'` es para el aprendizaje de dos clases, que sus datos son divididos por un hiperplano.
- `Standardize` - Indica si se deben regular las variables predictoras antes de entrenar al clasificador.
- `ClassNames`- Especifica las dos clases a utilizar.

Los datos usados para entrenar el modelo

$$X_train = [X1_train; X2_train];$$

$$Y_train = [Y1_train; Y2_train];$$

Al tener el modelo de SVM entrenado, este incluye los parámetros optimizados de este algoritmo, y esto permite clasificar los datos.

Para la clasificación de la SVM se utiliza el comando “*predict ()*”, donde se utiliza el modelo entrenado de la SVM, y se define un código de la forma:

```
[label, score] = predict(M, X_test(:,4));  
table(Y_test, label, score(:,2), 'VariableNames', ...  
      {'TrueLabel', 'PredictedLabel', 'Score'})
```

- *Label* representa la clasificación de cada fila en X.

Para que la SVM se ajuste correctamente, se eligieron algunos parámetros como, 'KernelFunction', 'KernelScale', 'PolynomialOrder', y 'Standardize'.

Los datos usados para validar el modelo

Para los resultados se utilizó el método de Matriz de confusión, donde este muestra los datos obtenidos del modelo de SVM.

```
X_test = [X1_test; X2_test];  
Y_test = [Y1_test; Y2_test];
```

3 Análisis de Resultados

Se realizaron dos procedimientos para verificar el rendimiento del clasificador SVM, una fue la con base de datos de elaboración propia, de la cual las imágenes fueron suministradas por la clínica Medilaser de Neiva, y esta fue previamente revisada por una Especialista en Traumatología, y otra de origen ya existente. La base de datos de elaboración propia tuvo una totalidad de 86 imágenes de rayos X con diagnóstico de OA de rodilla y la base de datos (Knee Osteoarthritis Severity Grading Dataset), tuvo una totalidad de 2562 imágenes de rayos X igualmente con diagnóstico de OA de rodilla.

En las dos bases de datos utilizadas en el desarrollo del trabajo, se realizó el mismo proceso, el cual inició con un ROI de (158x209 píxeles) para que todas las imágenes tuvieran un mismo tamaño y se pasó a escala de grises para que fuese más sencillo extraer las características de cada una de las imágenes, se siguió con un preprocesamiento, continuando con la extracción de características mediante técnicas de segmentación, donde se llevó a cabo la extracción de 5 características (Área, Perímetro, Centroides, Longitud y Orientación) a cada una de las imágenes. De la cual solo se utilizó la distancia entre los centroides, puesto que en la revisión bibliográfica (Martinez, 2020) para el diagnóstico de la OA de rodilla para los grados I y II. Se encuentra que suelen ser muy similares en donde solo se tiene en cuenta la posible existencia de osteofitos o protuberancias en la masa ósea de la extremidad inferior del fémur y la extremidad superior de la tibia, Además de la distancia entre los centroides de las regiones de interés (extremidad Inferior del fémur y extremidad superior de la tibia) ya que esta patología a medida que se presenta, va desgastando el tejido cartilaginoso evidenciando la reducción del espacio entre la tibia y el fémur, seguido de la clasificación SVM y finalizando con la matriz de confusión para validar los datos, con la única diferencia de que en la base de datos de elaboración propia en la fase de clasificación se utilizó un Kernel polinomial y un Kernel de Base Radial (RBF), y en la base de datos de origen ya existente se utilizó un Kernel lineal, esta diferencia se debió a que en la base de datos de origen ya existentes la diferencia entre los grados I y II de OA de rodilla eran más notoria que en la base de datos de elaboración propia.

Los resultados del clasificador SVM son los siguientes:

En la Figura 3-1 se muestra el resultado obtenido de la clasificación SVM con la base de datos propia. Teniendo en cuenta que se utilizó el 30% de las imágenes de cada grado de OA para la validación de la SVM. Donde se obtuvo un acierto del 78% en las imágenes de grado I, teniendo en cuenta que para la validación se utilizó 9 imágenes de este grado, y un acierto del 88% en las imágenes de grado II, considerando que para la validación se utilizó 16 imágenes de este grado.

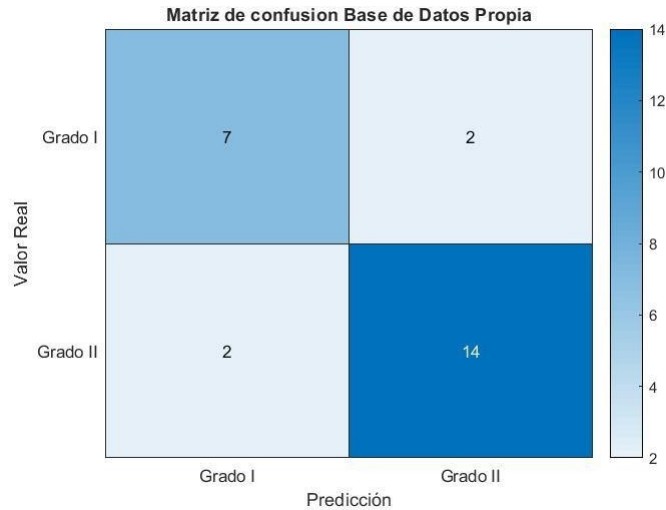


Figura 3-1: Matriz de confusión con los resultados base de datos propia, utilizando Kernel Polinomial.

Fuente: Elaboración propia




Figura 3-2: ROC primera SVM polinómica, relación verdaderos positivos y falsos positivos

Fuente: Elaboración propia

Además de lo descrito anteriormente, se realizó un segundo proceso para la base de datos de elaboración propia, el cual consistió en utilizar un Kernel RBF, debido que al implementar este Kernel la SVM mostro una mejor clasificación.

En la Figura 3-3, se visualiza el resultado obtenido de la clasificación SVM con la base de datos propia, utilizando un Kernel RBF. La cual obtuvo un acierto del 78% en las imágenes de grado I, puesto que, para la validación se utilizó 9 imágenes de este grado, y un acierto del 94% en las imágenes de grado II, considerando que para la validación se utilizó 16 imágenes de este grado.




Figura 3-3: Matriz de confusión con los resultados base de datos propia, utilizando RBF.

Fuente: Elaboración propia




Figura 3-4: ROC primera SVM RBF, relación verdaderos positivos y falsos positivos

Fuente: Elaboración propia

Como se visualiza en la Figura 3-3, tuvo un acierto del 72% en las imágenes de grado I, teniendo en cuenta que se utilizó un total de 313 imágenes de este grado, y un acierto del 73% en las imágenes de grado II, teniendo en cuenta que se utilizó un total de 454 imágenes de este grado.

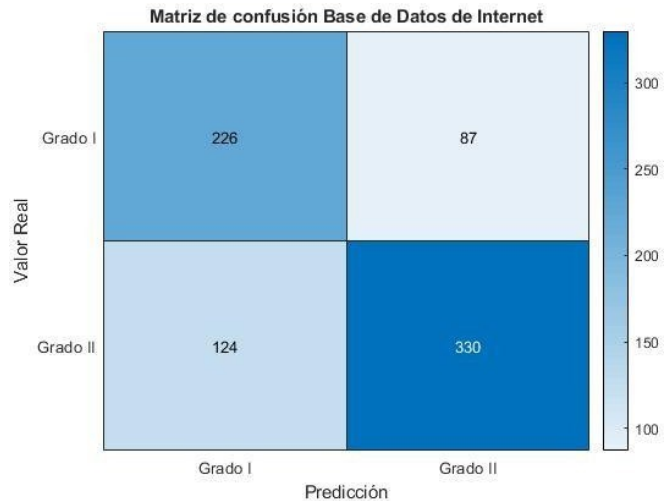


Tabla 3-5: Matriz de confusión con los resultados base de datos (Knee Osteoarthritis Severity Grading Dataset)

Fuente: Elaboración propia




Figura 3-6: ROC segunda SVM lineal, relación verdaderos positivos y falsos positivos

Fuente: Elaboración propia

3.1 Limitaciones

Debido a la situación actual por el Covid-19, se dificultó la adquisición de imágenes de RX de las demás sedes de la Clínica Medilaser en el país, obteniendo únicamente las imágenes de la Clínica Medilaser de Neiva para la elaboración de la base de datos. Debido a que el sistema de la salud se vio colapsado al tener que enfrentar la situación actual del país, y no contaban con el tiempo ni los recursos para solicitar imágenes de rayos X a las diferentes sedes de la Clínica Medilaser. Por lo tanto, se recurrió a la utilización de una base de datos ya existente con mayor cantidad de imágenes.

3.2 Discusiones

Al observar los resultados del clasificador SVM el cual tuvo un rendimiento del 78% en las imágenes de grado I y un 88% en las imágenes de grado II, utilizando el Kernel Polinomial. Teniendo en cuenta que se utilizó un Kernel RBF para esta misma base de datos del cual se obtuvo un acierto del 78% en las imágenes de grado I y un 94% en las imágenes de grado II, lo anterior se compara a su vez con la base de datos de origen ya existente en la cual se utilizó un Kernel Lineal y se obtuvo un acierto del 72% en las imágenes de grado I y el 73% en las imágenes de grado II. Se afirma que aunque la base de datos de elaboración propia tuvo una menor cantidad de imágenes, su porcentaje de acierto fue mayor, esto se debió a que en la base de datos de elaboración propia se utilizó el Kernel Polinomial y un Kernel RBF, los cuales permiten tomar un mayor rango de adaptación a los grados de OA de rodilla en las imágenes, a diferencia del Kernel Lineal el cual fue utilizado en la base de datos ya existente demostrando una menor adaptación a los diferentes grados de OA de rodilla implementados.

Por otra parte, la curva ROC de la base de datos propia utilizando el RBF muestra el área bajo la curva (AUC) con mayor probabilidad de clasificar correctamente los dos grados de OA de rodilla, a diferencia del AUC de la base de datos de elaboración propia utilizando el Kernel Polinomial y en la base de datos ya existente utilizando un Kernel Lineal. Esto debido a que los Falsos Positivos (FP) en la curva de la base de datos de elaboración propia con un Kernel RBF fueron más recurrentes a diferencia de las otras dos utilizando otros Kernel.

4 Conclusiones y recomendaciones

4.1 Conclusiones

En el curso de la presente investigación, logramos las siguientes conclusiones después de implementar el método de procesamiento de imágenes de rayos X:

- Se encontró que las imágenes utilizadas para la base de datos propia fueron limitadas, debido a la pandemia que se está viviendo en este momento, la Clínica Medilaser de Neiva solo pudo proporcionar 86 imágenes de rayos X con diagnóstico de Osteoartritis de rodilla grado I y II. Por esta razón, se utilizó una base de datos externa (Chen, 2018) con un total de 2562 imágenes, utilizando en esta un Kernel Lineal donde se obtuvo una mejora dando como resultado del área bajo la curva (AUC) un 75% de probabilidad de detectar correctamente el grado de OA, respecto a la base de datos propia en la cual se utilizó un Kernel Polinomial dando como resultado del AUC un 71% de probabilidad. Debido a los resultados anteriores se optó por utilizar un Kernel RBF en la base de datos de elaboración propia en la cual el AUC dio 91%, es decir, que se obtuvo una mejora significativa respecto a los dos resultados anteriores.
- Con respecto a nuestro tercer objetivo, el método empleado para la SVM, no fue completamente exacto, pero este obtuvo un resultado considerable en la evaluación de SVM utilizando un Kernel RBF, dando acierto del 78% en las imágenes de grado I y un 94% en las imágenes de grado II. Teniendo en cuenta que se extrajo múltiples características como (área, perímetro, centroide, extensión y orientación).
- De acuerdo con el planteamiento problema de la presente investigación, la conclusión que se extrae de los resultados obtenidos, es si es posible elegir un método de procesamiento de imágenes de rayos X que pueda sustentar el diagnóstico de artrosis de rodilla y otras lesiones traumáticas; a través de un preprocesamiento integrando métodos de segmentación y métodos de clasificación. El método de preprocesamiento se conformó por el filtro Wiener y el ecualizador de histograma, los cuales son fundamentales tanto para la etapa de segmentación como para la etapa de clasificación. Debido a que este método suaviza la imagen

eliminando el ruido y ajustando el contraste, dando un mejor resultado en la segmentación y en la clasificación.

- Este método de clasificación, sólo está acotado para detectar los grados I y II de OA de rodilla, al solo poder detectar estos dos grados, no se puede incluir los demás grados (III y IV) de OA de rodilla para la clasificación de la SVM.

4.2 Recomendaciones

Las recomendaciones y trabajos del presente trabajo de investigación son las siguientes:

- Se recomienda obtener más imágenes médicas de rayos X para futuros trabajos con el fin de obtener un mejor entrenamiento y precisión en las etapas de segmentación y clasificación.
- Se sugiere contar con el soporte de un especialista en esta área de Traumatología, para que haya validación absoluta de las imágenes de Rayos X que se van a usar, y que sean del grado de Osteoartritis correcto.
- Se recomienda utilizar otros lenguajes de programación, como: Python, C++; siendo que estos son lenguajes de alto nivel reduciendo carga computacional y de fácil acceso.
- La presente investigación tiene un grado de complejidad grande; es por esto que se recomienda como trabajos futuros el uso de los grados III y IV de esta patología; ya que en este trabajo solo se usaron los grados I y II de Osteoartritis. Además de lo nombrado anteriormente, se recomienda el uso de otros métodos de preprocesamiento, segmentación y clasificación como el método CLAHE u otros que sean adaptables a este clasificador (Koonsanit, 2017). Se recomienda llevar este método al campo del aprendizaje profundo (Kim, 2016), debido a que el sistema puede aprender y tomar decisiones de forma independiente.

5 Bibliografía

- Agarap FA. (2018). A Neural Network Architecture Combining Gated Recurrent Unit (GRU) and Support Vector Machine (SVM) for Intrusion Detection in Network Traffic Data. *10th International Conference on Machine Learning and Computing*, pp. 26-30.
- Alam S, K. M.-Y. (2016). Performance of classification based on PCA, linear SVM, and Multi-kernel SVM. *Eighth International Conference on Ubiquitous and Future Networks (ICUFN)*, pp. 987-989.
- Amat Rodrigo J. (2017, 04). *Máquinas de Vector Soporte (Support Vector Machines, SVMs)*. Retrieved from https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machines#Informaci%C3%B3n_sesi%C3%B3n
- Arregui Espinoza JM, Y. A. (2016). *Utilidad de rayos x digital en el diagnóstico de artrosis de rodilla en pacientes de 50 a 60 años de edad en el Hospital Privado Northospital de la ciudad de Quito*. Quito: UCE.
- Bradley J. Erickson, P. K. (2017). Machine Learning for Medical Imaging. *RadioGraphics*, vol. 37, no. 2.
- Braun, H. a. (2012). Diagnosis of osteoarthritis: Imaging. *Bone*, pp. 278-288.
- C. Cortes and V. Vapnik. (1995). Support-Vector Networks, Machine Learning. *Springer*, pp. 273-297.
- C. Wang, L. L. (2011). Face Recognition Based on Principle Component Analysis and Support Vector Machine. *3rd International Workshop on Intelligent Systems and Applications*, pp.1-4.
- Caleta, E. (2011). *Artritis de la rodilla*. Retrieved from Dr. Esteban Caleta Especialista en ortopedia y traumatología Reemplazos articulares, Cirugía artroscopica: <http://www.drestebancaleta.com.ar/index.php?PGN=51>
- Capapé, D. D. (2020). *Cirugía Ortopédica y Traumatología Deportiva*. Retrieved from Artrosis de rodilla (Gonartrosis): <http://doctorlopezcapape.com/cirugia-ortopedica/artrosis-de-rodilla-gonartrosis>
- Cardona H.D.V, O. Á. (2014). Automatic Recognition of Microcalcifications in Mammography Images through Fractal Texture Analysis. *Springer, Cham, Lecture Notes in Computer Science*, vol 8888.
- Carmona Suarez, E. (2016). Tutorial sobre Máquinas de Vectores Soporte (SVM). *Universidad Nacional de Educacion a Distancia (UNED), Madrid- España*, pp. 1-27.
- Cartas Solis U, P. H. (2015). Demography broad in the knees osteoarthritis. *Revista Cubana de Reumatología*, vol.17 no.1.

- Chen, P. (2018, 09 03). *Knee Osteoarthritis Severity Grading Dataset*. Retrieved from Mendeley: <https://data.mendeley.com/datasets/56rmx5bjcr/1>
- Cheng-Jin Du, D.-W. S. (2008). Histogram Equalization. *ScienceDirect*.
- Dhabhai, A. K. (2016). Empirical Study of Image Classification Techniques to Classify the Image using SVM: A Review. *International Journal of Innovative Research in Computer and Communication Engineering*, pp. 1-6.
- Dhabhai, A. K. G. (2016). Empirical Study of Image Classification Techniques to Classify the Image using SVM: A Review. *International Journal of Innovative Research in Computer and Communication Engineering*, pp. 1-6.
- drzezo. (2017, 04 20). *Imaging for osteoarthritis*. Retrieved from PHYSICAL MEDICINE & REHABILITATION : <https://musculoskeletalkey.com/imaging-for-osteoarthritis/>
- Farias Concha NM. (2011, 12). *MÁQUINAS VECTORIALES HÍBRIDAS PARA CLASIFICAR ACCIDENTES DE TRANSITO EN LA REGION METROPOLITANA* . Retrieved from Pontificia Universidad Catolica de Valparaiso : http://opac.pucv.cl/pucv_txt/Txt-9500/UCF9980_01.pdf
- Felson, D. (1988). Epidemiology of hip and knee osteoarthritis. *Oxford Journals*, pp.1-28.
- Fierro J. (01 de 05 de 2020). Director medico de la Clinica Medilaser de Neiva. (I. d. grado, Entrevistador)
- Flandry, F. M. (2011). Normal Anatomy and Biomechanics of the Knee. *Sports Medicine and Arthroscopy Review*, pp. 82-92.
- FULKERSON J P, G. H. (1980). Anatomy of the Knee Joint Lateral Retinaculum. *Clinical Orthopaedics and Related Research*, pp. 183-188.
- Garcia Balboa, J. F. (2018). Homogeneity Test for Confusion Matrices: A Method and an Example. *IEEE International Geoscience and Remote Sensing Symposium*, pp. 1203-1205.
- Garcia-Balboa, J. A.-F.-L.-A. (2018). Homogeneity Test for Confusion Matrices: A Method and an Example. *IEEE International Geoscience and Remote Sensing Symposium*, pp. 1203-1205.
- Gavrilov Z. (n.d.). *SVM Tutorial*. Retrieved from <https://web.mit.edu/zoya/www/SVM.pdf>
- Gonzalez R, B. A. (2017). Application of Support Vector Machines (SVM) for clinical diagnosis of Parkinson's Disease and Essential Tremor. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, pp. 394-405.
- Guermazi, A. D. (2015). Severe radiographic knee osteoarthritis – does Kellgren and Lawrence grade 4 represent end stage disease? – the MOST study. *Osteoarthritis and Cartilage*, pp. 1499-1505.
- Guo H, W. W. (2009). A novel learning model-Kernel Granular Support Vector Machine. *International Conference on Machine Learning and Cybernetics*, pp. 930-935.
- Guyon I, G. S. (2008). *Feature Extraction Foundation and Applications*. Poland: Springer.

- Haidekker, M. A. (2011). *Advanced Biomedical Image Analysis*. New Jersey: John Wiley & Sons. Inc.
- HEALTH, S. C. (2020). *Lesiones de ligamento de la rodilla*. Retrieved from STANFORD CHILDREN'S HEALTH:
<https://www.stanfordchildrens.org/es/topic/default?id=ligamentinjuriestotheeknee-85-P04023>
- Hertzmann A, F. D. (2015). *Support Vector Machines*. Retrieved from
<http://www.cs.toronto.edu/~mbrubake/teaching/C11/Handouts/SupportVectorMachines.pdf>
- Hu, J. Z. (2009). Curvilinear thresholding method for noisy images based on 2D histogram. *IEEE International Conference on Robotics and Biomimetics*, pp. 1014-1019.
- HUAN-JUN, L. y.-N.-F. (2005). A METHOD TO CHOOSE KERNEL FUNCTION AND ITS PARAMETERS FOR SUPPORT VECTOR MACHINES. *Fourth International Conference on Machine Learning and Cybernetics*, pp. 4277-4280.
- IArtificial.net. (n.d.). Retrieved from <https://www.iartificial.net/maquinas-de-vectores-de-soporte-svm/#:~:text=El%20truco%20del%20kernel%20consiste,con%20una%20superficie%20de%20decisi%C3%B3n>
- Jakkula V. (2006). *Tutorial on Support Vector Machine (SVM)*. Washington State: School of EECS, Washington State University.
- Khalid, R. R. (2015). Enhanced dynamic quadrant histogram equalization plateau limit for image contrast enhancement. *Fifth International Conference on Digital Information and Communication Technology and its Applications (DICTAP)*, pp. 86-91.
- Kim, K. G. (2016). Deep Learning. *Healthcare Informatics Research*, pp. 351-354.
- Koonsanit, K. T. (2017). Image enhancement on digital x-ray images using N-CLAHE. *Biomedical Engineering International Conference (BMEiCON)*, pp. 1-4.
- Kwang Gi, K. (2016). Deep Learning. *Healthcare Informatics Research*, pp. 351-354.
- Lopez Diaz, A. (2018). Fundamentos Matematicos de los Metodos Kernel para Aprendizaje Supervisado. *Universidad de Sevilla. DEPARTAMENTO: CIENCIAS DE LA COMPUTACION E INTELIGENCIA ARTIFICIAL*, pp. 1-73.
- López Pineda G. (2017, 05). *Modelos de regresión para datos funcionales por la metodología de Kernel reproductor en espacios de Hilbert*. Retrieved from BUAP:
<https://repositorioinstitucional.buap.mx/handle/20.500.12371/488>
- López-Portilla Vigil, B. M. (2016). Implementación del Algoritmo de Otsu sobre FPGA. *Revista Cubana de Ciencias Informáticas*. Retrieved from
http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2227-18992016000300002&lng=es&tlng=es.
- Lovejoy, C. (2007). The natural history of human gait and posture: Part 3. The knee. *Gait & Posture*, pp. 325-341.

- Luijckx, T. &. (2016). Kellgren and Lawrence system for classification of osteoarthritis of knee. Retrieved from <http://radiopaedia.org/articles/kellgren-and-lawrencessystem-for-classification-of-osteoarthritis-of-knee>
- Mark D. Kohn, A. A. (2016). Classifications in Brief: Kellgren-Lawrence Classification of Osteoarthritis. *Clinical Orthopaedics and Related Research*, pp. 1886-1893.
- Martinez Figueroa R, M. F. (2017). Knee Osteoarthritis (osteoarthrosis). *Revista Chilena de Ortopedia y Traumatología*, pp. 45-51.
- Martinez, D. A. (2020, 05 28). Características mas relevantes de la rodilla. (M. J. Bastos, Interviewer)
- Martínez, V. G. (2013). *TÉCNICAS DE UMBRALIZACIÓN PARA LA DETECCIÓN DE ANOMALÍAS EN LA PARED AÓRTICA MEDIANTE OCT*. UNIVERSIDAD DE CANTABRIA .
- Matlab. (2020). *MathWorks*. Retrieved from regionprops: <https://www.mathworks.com/help/images/ref/regionprops.html>
- Matlab. (2020). *MathWorks*. Retrieved from Support Vector Machines for Binary Classification: <https://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html>
- Matlab. (2020). *MathWorks*. Retrieved from Support Vector Machines for Binary Classification: <https://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html>
- MLMath.io. (2013, 02 13). *Math behind SVM(Support Vector Machine)*. Retrieved from <https://medium.com/@ankitnitjsr13/math-behind-svm-support-vector-machine-864e58977fdb>
- MLMath.io. (2019, 02 09). *Deep Learning*. Retrieved from Math behind SVM (Support Vector Machine): <https://medium.com/@ankitnitjsr13/math-behind-support-vector-machine-svm-5e7376d0ee4d#:~:text=SVM%20is%20one%20of%20the,versatile%20supervised%20machine%20learning%20algorithm.&text=The%20main%20objective%20of%20SVM,blue%20and%20pink%20classes%20balls>
- Mori, M. (2010). *Preprocessing techniques in character recognition*. Rijeka, Croatia: Character Recognition.
- Moya-Angeler J, V. J. (2016). Valuation of the degenerative process joint of the knee by magnetic resonance imaging. *Revista Latinoamericana de Cirugía Ortopédica*, pp. 88-94.
- Navale DI, H. R. (2015). Block based texture analysis approach for knee osteoarthritis identification using SVM. *IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE)*, pp. 338-341.
- Noble, W. (2006). What is a support vector machine? *Nat Biotechnol* , pp. 1565-1567.
- OTSU N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS*, VOL. SMC-9, NO. 1, pp.62-66.

- Pandey, M. B. (2018). An anatomization of noise removal techniques on medical image. *International Conference on Innovation and Challenges in Cyber Security (ICICCS-INBUSH)*, pp. 224–229.
- Paoletti ME, H. M. (2020). Estudio Comparativo de Técnicas de Clasificación de Imágenes Hiperespectrales. *Revista Iberoamericana de Automática e Informática industrial*, pp. 129-137.
- Patin aka, F. (2003). An Introduction To Digital Image Processing. pp.1-49.
- Pineda, G. L. (2017). *Modelos de regresión para datos funcionales por la metodología de Kernel reproductor en espacios de Hilbert*. Benemérita Universidad Autónoma de Puebla. Retrieved from <https://hdl.handle.net/20.500.12371/488>
- Pizzi, N. P. (2006). Confusion Matrix. *ScienceDirect*.
- Q. Wang, H. Z. (2012). Algorithm for segmentation based on an improved three-dimensional Otsu's thresholding. *International Conference on Computer Science and Network Technology*, pp. 1737-1740.
- Rajith B., S. M. (2016). Edge Preserved De-noising Method for Medical X-Ray Images Using Wavelet Packet Transformation. *Emerging Research in Computing, Information, Communication and Applications. Springer, New Delhi*.
- Rajith, B. S. (2016). Edge Preserved De-noising Method for Medical X-Ray Images Using Wavelet Packet Transformation. *Emerging Research in Computing, Information, Communication and Applications. Springer, New Delhi*.
- Ramamurthy, P. (1995). FACTORS CONTROLLING THE QUALITY OF RADIOGRAPY AND THE QUALITY ASSURANCE. *X-ray*, pp. 37-41.
- Ramon Alcala J, N. G. (2008). *La imagen digital y su tratamiento*. Cuenca: MIDECIANT .
- Roman V. (2019, 03 29). *Aprendizaje Supervisado: Introducción a la Clasificación y Principales Algoritmos*. Retrieved from Medium: <https://medium.com/datos-y-ciencia/aprendizaje-supervisado-introducci%C3%B3n-a-la-clasificaci%C3%B3n-y-principales-algoritmos-dadee99c9407>
- Russ, J. (1990). *Image Processing. In: Computer-Assisted Microscopy*. Boston, MA: Springer.
- S. Han, C. Q. (2014). Parameter selection in SVM with RBF kernel function. *World Automation Congress 2012, Puerto Vallarta, Mexico*, pp. 1-4.
- Sahu SK, P. A. (2015). GP-SVM: Tree Structured Multiclass SVM with Greedy Partitioning. *International Conference on Information Technology (ICIT)*, pp. 142-147.
- Shamir L, L. S. (2009). Early detection of radiographic knee osteoarthritis using computer-aided analysis. *Osteoarthritis and Cartilage*, pp. 1307-1312. vol 17.
- Shamir, L. (2009). Knee X-Ray Image Analysis Method for Automated Detection of Osteoarthritis. *IEEE Transactions on Biomedical Engineering*, pp. 407-415.

- Sharma S, S. V. (2016). Detection of Osteoarthritis using SVM. *International Conference on Computing for Sustainable Global Development (INDIACom)*, pp. 2997-3002.
- Solis Cartas U, C. B. (2018). Comorbidities and quality of life in Osteoarthritis. *Revista Cubana de Reumatología*, vol.20 no.2.
- Solis Cartas, U. d. (2014). Osteoarthritis. Características sociodemográficas. *Revista Cubana de Reumatología*, pp. 97-103 no.2.
- Sonka M, H. V. (2013). *Image Processing, Analysis, and Machine Vision*. EEUU: Cengage Learning.
- Suykens J. A. K, S. (2001). Nonlinear modelling and support vector machines. *18th IEEE Instrumentation and Measurement Technology Conference*, pp. 287-294.
- Szeliski, R. (2011). *Computer Vision*. Washington, USA: Springer.
- Thimmiaraja, J. S. (2014). Histogram Equalization for Image Enhancement Using MRI Brain Images. *World Congress on Computing and Communication Technologies*, pp. 80-83.
- Tromberg BJ. (n.d.). *Tomografía Computarizada (TC)*. Retrieved from National Institute of Biomedical Imaging and Bioengineering: <https://www.nibib.nih.gov/espanol/temas-cientificos/tomograf%C3%ADa-computarizada-tc>
- Turner A Blackburn, M. E. (1980). Knee Anatomy: A Brief Review. *Physical Therapy*, pp. 1556-1560. vol 60, Issue 12.
- Viatela Ardila, G. (2001). *Curso Tecnología de la Información y Comunicaciones por Video Interactivo*. Bogota D.C: IICA.
- Wang R. (2016, 08 19). *Soft Margin SVM*. Retrieved from Support Vector Machine: <http://fourier.eng.hmc.edu/e161/lectures/svm/node5.html>
- Wang, Q. Z. (2012). Algorithm for segmentation based on an improved three-dimensional Otsu's thresholding. *International Conference on Computer Science and Network Technology*, pp. 1737-1740.
- Xu K, W. C. (2014). A MapReduce based Parallel SVM for Email. *JOURNAL OF NETWORKS, VOL. 9, NO. 6*, pp. 1640-1646.
- Yang Y, W. J. (2012). Improving SVM classifier with prior knowledge in microcalcification detection1. *IEEE International Conference on Image Processing*, pp. 2837-2840.
- Yin-Wen C, C.-J. L. (2008). Proceedings of the Workshop on the Causation and Prediction Challenge at WCCI. *PMLR*, pp. 53-64.
- Yu, D. L. (2009). Otsu Method and K-means. *Ninth International Conference on Hybrid Intelligent Systems, Shenyang*, pp. 344-349.
- Zahurul S, Z. S. (2010). An Adept Edge Detection Algorithm for Human Knee Osteoarthritis Images. *International Conference on Signal Acquisition and Processing*, pp.375-379.

- Zhang Y, J. J. (2010). Epidemiology of Osteoarthritis. *Clinics in Geriatric Medicine*, pp. 355-369.
- Zhou, S. K. (2016). *Medical Image Recognition Segmentation and Parsing*. London UK, San Diego CA: ELSEVIER. INC.

