

UNIVERSIDAD POLITÉCNICA DE PUEBLA

Programa Académico de Maestría en Ingeniería



“CLASIFICACIÓN AUTOMÁTICA DE RETINOPATÍA
DIABÉTICA BASADA EN IMÁGENES”

TESIS DE GRADO DE MAESTRÍA

GUDELIA PILAR PÉREZ CONDE

Juan C. Bonilla, Puebla.

Noviembre 2012

UNIVERSIDAD POLITÉCNICA DE PUEBLA

Programa Académico de Maestría en Ingeniería



“CLASIFICACIÓN AUTOMÁTICA DE RETINOPATÍA
DIABÉTICA BASADA EN IMÁGENES”

GUDELIA PILAR PÉREZ CONDE

TESIS DE GRADO DE MAESTRÍA

COMITÉ EVALUADOR

DR. JORGE DE LA CALLEJA MORA
ASESOR

DRA. MARÍA AUXILIO MEDINA NIETO
SINODAL

DR. ANTONIO BENITEZ RUÍZ
SINODAL

Juan C. Bonilla, Puebla.

Noviembre 2012

Índice

1. Planteamiento del problema de investigación	1
1.1. Introducción	1
1.2. Objetivo general	3
1.3. Objetivos específicos	4
1.4. Justificación	4
1.5. Contribuciones esperadas	6
2. Marco teórico y Estado del Arte.	7
2.1. Retinopatía diabética	7
2.2. Procesamiento de imágenes	8
2.2.1. Técnicas de procesamiento de imágenes	10
2.3. Reducción y caracterización de imágenes	12
2.3.1. Análisis de componentes principales	12
2.3.2. Red neuronal de Hinton	14
2.4. Aprendizaje automático	16
2.4.1. Tipos de aprendizaje automático	18
2.4.2. Algoritmos de aprendizaje	19
2.5. Métricas de evaluación	28
2.6. Estado del arte	30

2.6.1. Discusión	31
3. Método automático de clasificación	35
3.1. Método propuesto para clasificar las imágenes de la retinopatía diabética	35
3.2. Procesamiento de imágenes	36
3.3. Reducción y caracterización de imágenes	36
3.3.1. Análisis de componentes principales	37
3.3.2. Modelo de la red neuronal de Hinton	38
3.4. Clasificación usando algoritmos de aprendizaje automático	39
4. Resultados Experimentales	41
4.1. Datos	41
4.2. Clasificación y evaluación	41
4.3. Resultados procesamiento de las imágenes	42
4.4. Resultados de la reducción, caracterización y clasificación	43
4.4.1. Resultados con el método de <i>PCA</i>	43
4.4.2. Resultados de la la red neuronal de Hinton	76
5. Conclusiones	108
Bibliografía	113

Capítulo 1

Planteamiento del problema de investigación

1.1. Introducción

El ser humano, para poder sobrevivir e interactuar en su medio ambiente, necesita obtener información de lo que ocurre en el mundo que lo rodea. Así, el cuerpo humano está provisto de órganos que permiten sentir su entorno de tal manera que pueda captar la energía y convertirla en impulsos eléctricos que son transmitidos al cerebro, donde se interpretan y en consecuencia se reacciona. Por ejemplo, los ojos permiten captar y transformar la energía en forma de luz, los oídos en sonido; mientras que la piel es sensible a la energía en forma de temperatura, presión o contacto.

La vista podría considerarse una de las principales capacidades sensoriales que tiene el ser humano, ya que a través de ella se obtiene la mayor parte de la información que se presenta alrededor. Pero con el paso del tiempo, este sentido se puede ir degenerando debido a múltiples factores que van desde los problemas genéticos hasta factores ambientales o artificiales.

En México, la pérdida del sentido de la vista ha incrementado en años recientes, así como en otros países [9, 51]. Estadísticamente la diabetes muestra ser la principal causa de ceguera y se estima que para el 2025 habrá unos 300 millones de diabéticos en el mundo, lo que provoca la aparición de enfermedades en los ojos como el glaucoma y la retinopatía diabética, siendo esta última la principal causa de deficiencia visual y ceguera [40].

Actualmente las nuevas tecnologías médicas proporcionan mediciones cuantitativas de las estructuras del ojo humano de forma más objetiva como la cabeza del nervio óptico, las fibras nerviosas de la retina, etc. De esta manera, los médicos pueden auxiliarse para diagnosticar oportunamente el estado del ojo y evitar la aparición de una enfermedad o la expansión de la misma. Algunas de estas herramientas son los analizadores de imágenes como el láser de barrido confocal *Heidelberg Retina Tomograph* (HRT), la tomografía de baja coherencia óptica (OCT), la polarimetría láser con compensación corneal (GDx-VCC) [6], entre otros.

Con estas herramientas se puede obtener una gran variedad de tipos de imágenes para encontrar alguna deformación de la retina o alguna otra parte del ojo (parte interna). Por ejemplo, para la retina se tienen las siguientes imágenes: tomografías por emisión de positrones, una aplicación de este tipo de imagen es sobre la detección del melanoma coroideo [43]; técnicas modernas de imagen transversal en oftalmología que se han utilizado en [29] y fondo de imagen con RetCam, empleado para revisar cambios en el nervio o disco óptico [52]. Así también se tienen aquellas imágenes obtenidas por ecografía, biomicroscopía por ultrasonido, angiografía con fluorescencia y algunas tomadas por técnicas especiales entre las que se encuentran las siguientes [53]: fondo de imágenes de autofluorescencia (*Fundus autofluorescence imaging*), ángulo amplio de

angiografía por fluorescencia (*Wide angle fluorenscein angiography*), fondo de fotografía de campos Swven(*Swven field fundus photography*), imágenes estéreo (*Stereo-imaging*), angiografía del segmento anterior (*Anterior segment angiography*), angiografía con fluorescencia oral (*Oral fluorenscein angiography*).

Este trabajo de investigación tiene por objetivo desarrollar un método que permita clasificar de manera automática la presencia de Retinopatía Diabética en imágenes de fondo de ojo. El método propuesto básicamente constará de tres etapas: procesamiento, caracterización y clasificación de las imágenes. En la primera etapa se aplicarán filtros de procesamiento de imágenes con el objetivo de mejorar la calidad de las mismas y obtener mejor información. Enseguida, se reducirá la dimensionalidad de las imágenes y se obtendrán características, para finalmente clasificarlas de manera automática empleando algoritmos de aprendizaje automatizado. Para realizar los experimentos, las imágenes serán proporcionadas por el Hospital de Especialidades IMSS del Estado de Puebla.

En algunas investigaciones ya se han aplicado métodos de aprendizaje automático para detectar y clasificar algunas enfermedades por ejemplo, enfermedades de los ojos [19, 38, 57], detección y diagnóstico de cáncer de mama [21, 47], cáncer del pulmón [24, 56], así también para la clasificación de patrones del cerebro [31]. Otras aplicaciones más son el reconocimiento de emociones [26] y trastornos como el autismo [20].

1.2. Objetivo general

Desarrollar un método automático para clasificar imágenes de retinopatía diabética usando algoritmos de aprendizaje automático y procesamiento de imágenes.

1.3. Objetivos específicos

- Comparar los métodos de análisis de componentes principales y redes neuronales para la reducción y extracción de características en imágenes.
- Aplicar técnicas de procesamiento de imágenes para realzar y mejorar las características del conjunto de imágenes.
- Clasificar imágenes de retinopatía diabética en proliferativa y no proliferativa usando algoritmos de aprendizaje automático.

1.4. Justificación

Hoy en día, las personas están más expuestas a los diferentes tipos de radiación emitidas por diversas fuentes y particularmente los órganos más afectados son los ojos. Por ejemplo, el pasar muchas horas usando la computadora, ya sea por trabajo o entretenimiento; el estar frente al televisor; la exposición a los rayos ultra-violeta; la mala alimentación; así como el padecimiento de enfermedades como la diabetes e hipertensión [17, 30], entre otros factores; han propiciado que dicho órgano, sufra diversos tipos de daños. En consecuencia, la degeneración de las fibras del campo visual se incrementa con el paso del tiempo o por alguna patología de la retina, provocando la aparición de enfermedades en los ojos como pueden ser el glaucoma, cataratas, conjuntivitis, queratitis, escleritis, uveítis, retinopatía diabética, degeneración pigmentaria de la retina, degeneraciones maculares, angiomatosis de la retina, entre otras [35]. Además, hoy en día estas enfermedades no sólo se presentan en personas adultas sino también en personas jóvenes.

En México el índice de personas con diabetes se encuentra entre 6.5 y 10 millones [10], ya que cada hora se diagnostican 38 nuevos casos [45], lo que provoca un incremento de la presencia de retinopatía diabética [13, 48, 54]. El número incrementa debido a que los pacientes no reciben atención oportuna o tratamiento adecuado para evitar la evolución de la enfermedad en sus diferentes fases; así como por la falta de información y descuidos por parte del paciente. Algunas organizaciones como la OMS (Organización Mundial de la Salud) le dan prioridad a la búsqueda de nuevas soluciones para evitar la pérdida temprana del sentido de la vista [1].

La clasificación de imágenes de enfermedades visuales en la mayoría de los casos aún se lleva a cabo de forma manual, esto implica una demora de tiempo para realizar dicha tarea, lo que conlleva a que algunas veces no se concluya la actividad debido a que existe un gran número de imágenes a evaluar y además en ocasiones el ojo humano de un especialista no alcanza a visualizar algunos detalles que puedan ayudar a determinar a qué clase pertenece alguna imagen.

En la actualidad con el avance de las nuevas tecnologías y la aplicación de la Inteligencia Artificial con sus diversas ramas, siendo una de ellas el Aprendizaje Automático, el cual permite que las computadoras “aprendan” de ejemplos anteriores usando sus diversas técnicas estadísticas, probabilísticas y de optimización, para después poder realizar múltiples tareas automáticas tales como el reconocimiento de algún patrón o la clasificación de una enfermedad, logrando así reducir el tiempo de ejecución de dicha tarea, además esto puede facilitar y agilizar el procesamiento de un conjunto grande de imágenes y la toma de decisiones.

1.5. Contribuciones esperadas

La realización de este trabajo de investigación puede proporcionar algunos elementos que pueden ayudar en diversos aspectos, estas aportaciones se muestran a continuación:

- Un método automático para clasificar imágenes de enfermedades de los ojos.
- La reducción y caracterización de imágenes usando los métodos de análisis de componentes principales y redes neuronales.
- La clasificación de dos tipos de retinopatía diabética, proliferativa y no proliferativa.
- Proporcionar una base de conocimiento del desempeño de diferentes algoritmos de aprendizaje para una futura implementación de un sistema de detección de enfermedades en tiempo real.
- Un estudio experimental con datos reales de las poblaciones de Puebla, Tlaxcala y Oaxaca.

Capítulo 2

Marco teórico y Estado del Arte.

2.1. Retinopatía diabética

La retinopatía diabética es esencialmente una microangiopatía (una anomalía de la participación de los vasos sanguíneos pequeños) que se dirige a la región central, es decir la mácula, más que a cualquier otra parte de la retina [18]. La retinopatía diabética se clasifica convencionalmente en **no proliferativa** y **proliferativa**, en la tabla 2.1 se muestra la clasificación con sus diferentes fases [40].

Algunas manifestaciones de la **retinopatía diabética no proliferativa (RDNP)** son: microaneurismas, hemorragias intrarretinianas, exudados blandos y duros, anomalías en la zona avascular foveal (ZAF) y edema macular (ver Figura 2.1a). Mientras que la **retinopatía diabética proliferativa (RDP)** se caracteriza por la aparición de neovascularización en el disco óptico o en otras partes de la retina, hemorragias prerretinianas vítreas, proliferación fibrosa y desprendimiento de retina por tracción (ver Figura 2.1b) [11, 40].

Para la detección de la retinopatía diabética existen diversos métodos, uno de ellos

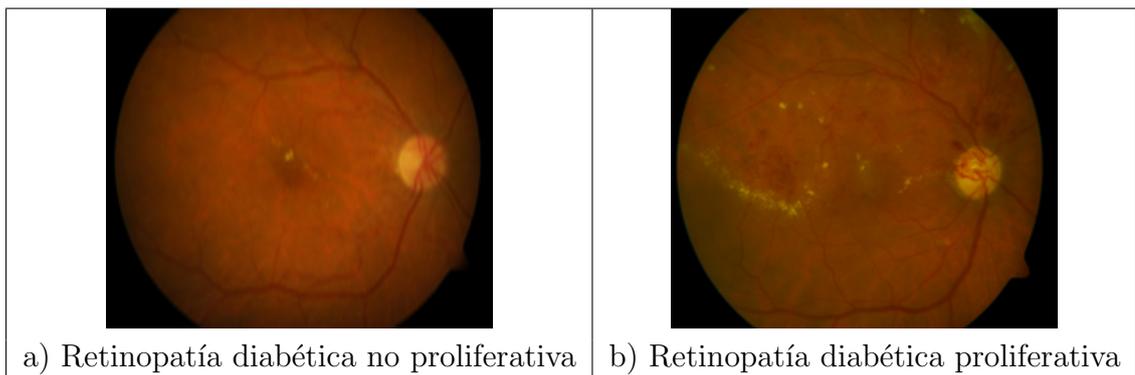


Figura 2.1: Ejemplos de los tipos de retinopatía diabética [37].

es el examen de fondo de ojo. Esta exploración sirve para ver la parte interna del ojo (la retina); con esto se puede observar las venas, arterias así como las estructuras de la retina como la papila y mácula. Las imágenes se obtienen a través de una cámara de fondo, la cual permite utilizar diversos filtros (azul, verde, rojo) o también se puede emplear colorantes con filtros especiales para destacar alguna patología [16, 46].

2.2. Procesamiento de imágenes

El procesamiento de imágenes digitales tiene sus inicios a finales de los 60's y principios de los 70's para ser usado en imágenes médicas, en observaciones remotas de los recursos terrestres y la astronomía. Otras aplicaciones se encuentran en la industria, medicina, ciencias biológicas, la geología y física [39].

El objetivo del procesamiento de imágenes digitales es mejorar el contraste o los niveles de intensidad del color para facilitar la interpretación de la imagen.

Una imagen se puede definir como una función bidimensional $f(x, y)$, donde x e y son coordenadas espaciales, la amplitud de f para cualquier par de coordenadas (x, y)

Tabla 2.1: Clasificación convencional de la retinopatía diabética [40]

Tipo	Fase	Características
NRD No hay presencia de RD		Diabetes mellitus sin lesiones oftalmoscópicas
	Leve	Microaneurismas, hemorragias retinianas, exudados duros y blandos.
RDNP	Moderada	Microaneurismas, exudados blandos, microhemorragias retinianas moderadas y escasas AMIR.
	Grave	Hemorragias, microaneurismas severos en los 4 cuadrantes o AV en 2 o más cuadrantes, AMIR en por lo menos un cuadrante.
	Muy grave	Coexisten 2 de los 3 criterios de la RDNP grave
	Sin características de alto riesgo (sinCAR)	NVE de cualquier extensión sin HV/HP; NVD de extensión inferior a la cuarta parte del área del disco
RDP	Con características de alto riesgo (conCAR)	NVD de extensión igual o mayor a la cuarta parte del área papilar; HP/HV con NVD de cualquier extensión o con NVE igual.
	Avanzada	HV muy extensas (no permiten valorar neovasos); desprendimiento de retina macular traccional; glaucoma neovascular

es la intensidad de la imagen en ese punto. Una imagen digital es cuando x, y y los valores de la intensidad de f son cantidades finitos y discretas. Todos los elementos finitos que componen una imagen los cuales tienen un lugar y valor en particular se conocen comúnmente como píxeles [39].

Se pueden considerar tres tipos de proceso computarizado: proceso de nivel bajo,

medio y alto. El primero involucra operaciones primitivas como el preprocesamiento de una imagen para reducir el ruido, aumentar el contraste y la nitidez de la imagen. El nivel bajo se caracteriza porque las entradas y salidas siempre son imágenes.

En el nivel medio se realizan tareas como la segmentación (particionar una imagen en regiones u objetos), la descripción de estos objetos reducirá a una forma adecuada para el proceso computacional y clasificación (reconocimiento) de objetos individuales, este nivel se caracteriza porque generalmente sus entradas son imágenes pero sus salidas son atributos (características) extraídos de esas imágenes, por ejemplo bordes, esquinas.

Para el nivel alto existe la capacidad de dar sentido a un conjunto de objetos reconocidos como el análisis de una imagen o la realización de las funciones cognitivas asociadas normalmente con la visión [39].

2.2.1. Técnicas de procesamiento de imágenes

Para este trabajo se usarán las siguientes técnicas de procesamiento: el detector de bordes Canny; la textura de imagen filtro de rango (*range-filter*); el método de ecualización del histograma y binarización.

Detector de bordes Canny

El algoritmo Canny usa un detector de bordes óptimo sobre un conjunto de criterios los cuales incluyen encontrar más bordes para minimizar la tasa de error, marcando todos los bordes cercanos como sea posible para maximizar la localización de los bordes actuales. Este detector trabaja de la siguiente manera, primero se obtiene un gradiente, en este paso se aplica un filtro gaussiano para suavizar la imagen para después calcular la magnitud y orientación del vector gradiente en cada píxel. A continuación se realiza

la supresión no máxima, en donde se logra un adelgazamiento del ancho de los bordes obtenidos con el gradiente, hasta lograr bordes de un píxel de ancho. Finalmente se aplica una función de histéresis basada en dos umbrales, con el objetivo de reducir la aparición de contornos falsos [33].

Textura de la imagen *Range-filter*

La técnica de *range-filter* calcula un rango local de la imagen, el cual provee información acerca de la variación local de los niveles de intensidad de los pixeles, donde en las áreas uniformes son cero y en las áreas no uniformes el valor es mayor a cero. Por tanto la extracción de un borde es realizado proporcionando pixeles de salida los cuales contienen el valor de rango (valor máximo - valor mínimo) de los 3×3 vecinos que se encuentran alrededor del pixel correspondiente en la imagen de entrada [7].

Ecuación del histograma

La ecualización del histograma es un método no lineal usado ampliamente para realzar las imágenes. Es un método no paramétrico que hace coincidir la función de la distribución acumulativa de una imagen dada con una distribución de referencia. Este método emplea un mapeo lineal monótono, el cual reasigna los valores de intensidad de los pixeles en la imagen de entrada con el fin de controlar la forma del histograma de intensidad de la imagen de salida para lograr una distribución uniforme de la intensidad o para destacar ciertos niveles de intensidad [14].

Método de binarización

Una imagen binaria es aquella en donde cada pixel puede tener solo un valor posible 0 ó 1. El método para obtener este tipo de imágenes es mediante la utilización del valor de umbral de una imagen a escala de grises, es decir elige un intervalo a partir del

cual todos los valores de intensidades mayores serán codificados como 1 y los que se encuentren por debajo de este valor serán codificados como 0.

Para elegir el umbral óptimo y realizar una binarización adecuada, se pueden aplicar funciones como *graythresh*, esta función retorna un valor normalizado entre 0 y 1, el cual corresponde al mejor umbral que se debe aplicar a la imagen para obtener la binarización.

2.3. Reducción y caracterización de imágenes

El objetivo de reducir una imagen en cuanto a su dimensionalidad y obtener sus características, es para disminuir el poder computacional y el tiempo de ejecución cuando se realizan tareas como la clasificación o reconocimiento de un objeto, entre otras.

Algunas técnicas son: Indexación Semántica Latente (*Latent Semantic Indexing (LSI)*); Análisis de Componente Independiente (*Independent Component Analysis (ICA)*); Análisis de Correlación Canónica (*Canonical Correlation Analysis CCA*); Análisis Discriminante Lineal, (*Linear Discriminant Analysis (LDA)*); y Análisis de Componentes Principales, (*Principal Component Analysis (PCA)*), que será utilizado para este trabajo. Así también se experimentará con la técnica de redes neuronales, para compararlo con el método de *PCA*. Esta técnica fue utilizada en el 2006 por Hinton para la compresión de datos [15], cabe decir que esta técnica no ha sido muy utilizada para la reducción y caracterización de imágenes.

2.3.1. Análisis de componentes principales

El Análisis de Componentes Principales o sus siglas en inglés *PCA*, fue creado por *Karl Pearson* (1901) y *Hotelling* (1933). El objetivo de *PCA* es reducir la dimension-

alidad con un porcentaje mínimo de pérdida de información y encontrar los vectores que reportan mejor la distribución de datos en todo el espacio del conjunto de datos [28].

Antes de iniciar el proceso de PCA, se debe realizar una estandarización al conjunto de datos para asegurar que todos tengan un peso igual en el análisis. Un método común para estandarizar es transformar todos los datos para tener una media cero y la unidad de la desviación estándar.

$$\frac{x_i - \mu}{\sigma} \quad (2.1)$$

donde σ y μ son la desviación estándar y media de x_i 's.

La metodología que lleva a cabo PCA es la siguiente [28]: Dado un conjunto de entrenamiento de datos I_1, I_2, \dots, I_M , donde cada dato I_i será representado como un vector Γ_i , M es el conjunto de entrenamiento. Por lo tanto el promedio del vector de un dato Ψ será calculado de la siguiente forma:

$$\Psi = \frac{1}{M} \sum_{i=1}^M (\Gamma_i) \quad (2.2)$$

donde cada dato difiere del promedio por el vector, es decir se subtrae la media del dato:

$$\Phi_i = \Gamma_i - \Psi$$

Este conjunto de vectores grandes se somete al análisis de componentes principales, los cuales buscan un conjunto de M vectores ortonormales, u_n , y los eigenvalores (escalares) λ_k respectivamente, los cuales describen mejor la distribución de los datos. Los eigenvectores u_k y eigenvalores λ_k son obtenidos de la matriz de covarianza C (ver ecuación 2.3). Los eigenvalores y eigenvectores proporcionan información acerca de los patrones

en los datos.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (2.3)$$

donde la matriz $A = [\Phi_1 \Phi_2 \dots \Phi_M]$.

El k_{th} vector u_k es elegido de tal manera que

$$\lambda_k = \frac{1}{M} \sum_{n=1}^M (u_k^T \Phi_n)^2 \quad (2.4)$$

es un máximo, sujeto a

$$u_l^T u_k = \delta_{lk} = \begin{cases} 1, & \text{if } l = k \\ 0, & \text{en otro caso} \end{cases} \quad (2.5)$$

Para elegir los componentes principales, se ordenan los eigenvectores de acuerdo a sus eigenvalores de mayor a menor para descartar los menos significativos, si el valor de los eigenvalores es pequeño, la pérdida de información es menor.

2.3.2. Red neuronal de Hinton

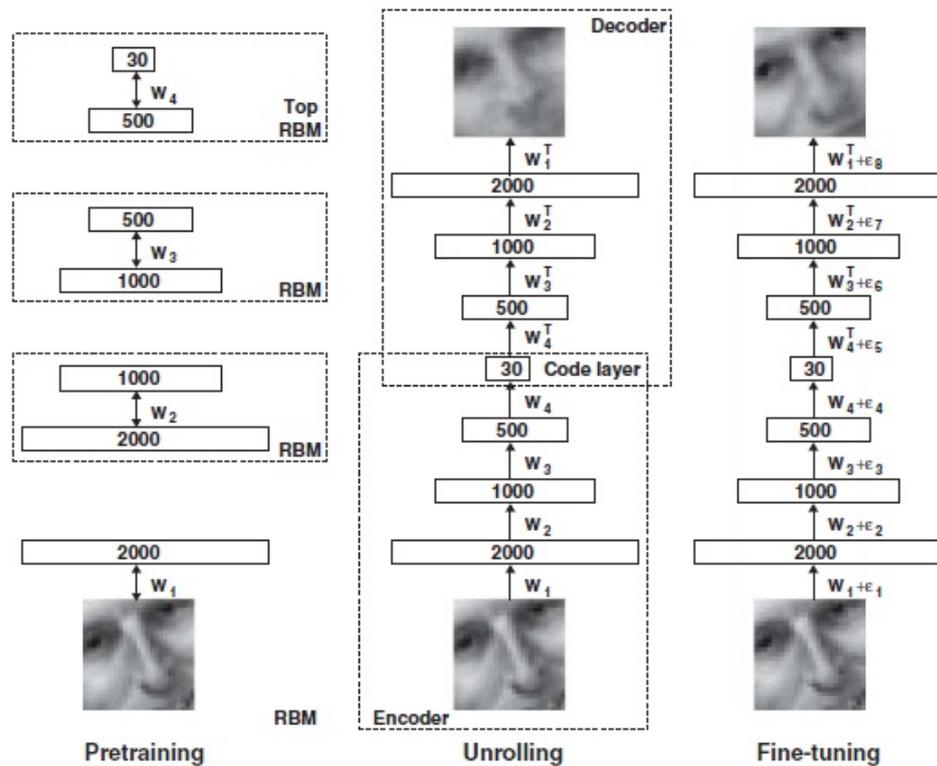
Esta forma de reducir y caracterizar imágenes fue propuesto por G. E. Hinton y R.R. Salakhutdinov en el 2006 y de acuerdo con los resultados presentados funciona mejor que el análisis de componentes principales al obtener un valor mínimo de error de reconstrucción usando un número menor de características en el proceso [15].

El método es una generalización no-lineal de *PCA* el cual usa una red codificadora adaptativa multicapa (*encoder*) para transformar los datos de una dimensión grande a un código de baja dimensión y de forma similar trabaja la red decodificadora (*decoder*) para recuperar los datos del código.

Al conjunto de las dos redes *encoder* y *decoder* se les llama sistema *autoencoder*. Este sistema inicializa con pesos aleatorios en las dos redes las cuales pueden ser entrenadas al mismo tiempo para disminuir la discrepancia entre los datos originales y su reconstrucción. Los gradientes requeridos son obtenidos por la regla de la cadena para retropropagar (*backpropagate*) el error derivado, primero a través de la red decodificadora y después en la red codificadora.

Debido a la complejidad para optimizar los pesos en un *autoencoder* no-lineal, los autores introducen un procesamiento llamado pre-entrenamiento el cual consiste de un ensamble de vectores binarios (por ejemplo, imágenes), que puede ser modelado usando una red de dos capas llamada *Restricted Boltzmann Machine (RBM)*. Este proceso consiste en aprender de un gran número de *RBM*'s, cada uno con una sola capa de detectores de características. La activación de la característica aprendida de un *RBM* se usa como “dato” para entrenar el siguiente *RBM* de la pila.

Para comprender mejor el funcionamiento del sistema *autoencoder* (ver Figura 2.2), lo podemos visualizar de la siguiente forma: como se sabe el modelo del sistema es una red neuronal, en este caso se tiene dos redes una llamada codificadora y decodificadora, la primera *encoder* toma una imagen en su tamaño normal y la va reduciendo en cada capa por la que pasa, hasta obtener una imagen adecuada para los cálculos que se realizarán. Como se muestra en la Figura 2.2 el *encoder* que tiene como entrada una imagen de tamaño 2000 después pasa a 1000 hasta llegar a 30, la red decodificadora se encarga de hacer lo mismo pero de manera contraria. La fase de ajuste es para obtener una imagen lo más proxima a la original y el pre-entrenamiento es para obtener los pesos iniciales para que el *autoencoder* tenga un sesgo mínimo y genere mejores resultados.

Figura 2.2: Sistema *autoencoder* [15]

2.4. Aprendizaje automático

El aprendizaje automático es una rama de la Inteligencia Artificial, dentro de las ciencias computacionales, cuyo principal objetivo es desarrollar programas que permitan a las computadoras tener la capacidad de “aprender” [50].

Una definición de aprendizaje automático, se puede ejemplificar de la forma siguiente: un programa de computadora “aprende” de la experiencia \mathbf{E} con respecto a un tipo de tarea \mathbf{T} y mide su desempeño \mathbf{P} , si el desempeño en la tarea \mathbf{T} medida por \mathbf{P} , mejora con la experiencia \mathbf{E} [50].

El aprendizaje automático no es una disciplina aislada, sino que se relaciona con una

gran diversidad de disciplinas como son la teoría de control, la teoría de información, la psicología, la neurobiología, la filosofía, la estadística, la teoría de la complejidad computacional, entre otras; para comprender mejor los procesos de aprendizaje de un humano y utilizar los parámetros e información adecuada para la construcción y desarrollo de algoritmos que puedan efectuar tareas imitando al ser humano [50].

Algunas aplicaciones exitosas que han involucrado al aprendizaje automático son: el reconocimiento de rostros, el reconocimiento de voz, algunas detecciones de enfermedades, detección de fraudes de tarjetas de crédito, clasificación de objetos astronómicos, reconocimiento de secuencias de ADN, reconocimiento de patrones, análisis del mercado de valores, aplicaciones en videojuegos y robótica, entre muchas otras más.

Para resolver cualquier problema de aprendizaje, se tiene que tener en cuenta el tipo de tarea \mathbf{T} que se realizará, cómo se va medir el desempeño \mathbf{P} para mejorar y cuál será la fuente que le proporcionará experiencia \mathbf{E} .

Algunos términos y simbología que se usarán en esta sección son los siguientes:

- X es el conjunto de elementos, por lo tanto $x_i \in X$ es una instancia de X .
- c es la tarea u objetivo a “aprender”.
- D denota el conjunto de ejemplos disponibles.

El proceso para realizar una tarea que involucre aprendizaje automático (ver Figura 2.3), consta básicamente de las siguientes etapas:

1. Definir c , en este ejemplo mostrado en la Figura 2.3, la tarea es aprender a reconocer la letra B.

2. Seleccionar un conjunto de datos que serán utilizados para entrenar al algoritmo de aprendizaje automático y éste pueda “aprenderse” la tarea. A este conjunto de datos se le llamará **conjunto de ejemplos de entrenamiento**.
3. Seleccionar el algoritmo que mejor se desempeñe para ejecutar la tarea.
4. Seleccionar un conjunto de datos que serán utilizados para probar el desempeño del algoritmo de aprendizaje automático sobre la tarea. Este conjunto de datos se le conoce como **conjunto de ejemplos de prueba**.

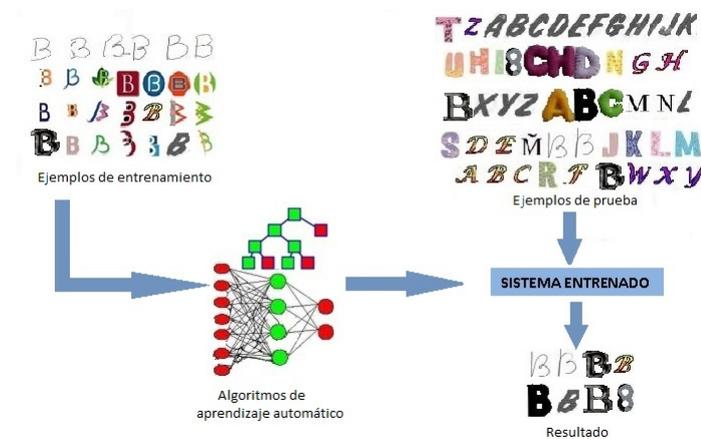


Figura 2.3: Ejemplo del Proceso de aprendizaje automático, para este caso el objetivo es aprender a reconocer la letra B.

2.4.1. Tipos de aprendizaje automático

Generalmente, el aprendizaje automático se divide en dos tipos: aprendizaje supervisado y aprendizaje no supervisado, los cuales se describen a continuación.

Aprendizaje supervisado

El aprendizaje supervisado es aquel en donde los algoritmos reciben como entrada al conjunto de entrenamiento etiquetado con su respectiva clase, para saber el resultado

correcto de la salida para cada uno de los datos [44]. Un ejemplo sería el reconocimiento de rostros, donde cada uno de los datos del conjunto de entrenamiento es etiquetado como 1 para los rostros y 2 para otros,

Aprendizaje no supervisado

El aprendizaje no supervisado se caracteriza porque los algoritmos reciben únicamente como parámetros de entrada los datos de entrenamiento, que estos a su vez no van etiquetados con la clase a la que pertenecen, por lo tanto los algoritmos se adaptarán al conjunto de datos para ejecutar alguna tarea.

La tarea más frecuente en este tipo de aprendizaje es el *clustering* [44].

2.4.2. Algoritmos de aprendizaje

Árboles de decisión

Este método de aprendizaje es el más usado y práctico para la inferencia inductiva. Es un método de aproximación, robusto al ruido y capaz de aprender expresiones disyuntivas. Algunos algoritmos que forman parte de la familia de árboles de decisión son *ID3*, *ASSISTAN* y *C4.5* [50].

Un árbol de decisión representa una función que toma como entrada un vector de valores de atributos y regresa una decisión, un solo valor de salida. Los valores de entrada y salida pueden ser discretos o continuos [44]. Por ejemplo, un árbol de decisión booleano consiste de un par (x, y) donde x es un vector de valores para los atributos de entrada e y es un solo valor booleano de salida.

Los árboles de decisión están compuestos por nodos internos que son las pruebas

para cada atributo de la instancia; cada rama descendiente de ese nodo corresponde a un valor posible de este atributo y los nodos hoja son el valor final de la prueba realizada desde la raíz (ver Figura 2.4). Un árbol se construye partiendo desde el nodo raíz

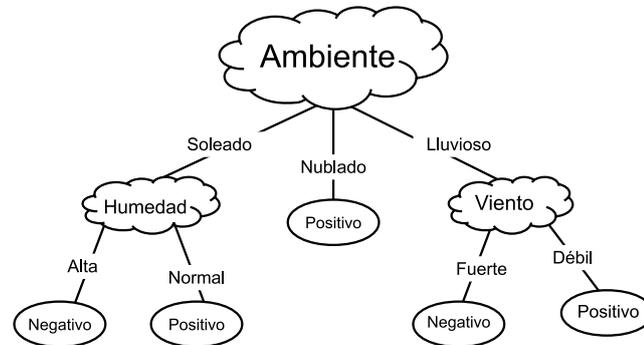


Figura 2.4: Ejemplo de un árbol de decisión.

que es el atributo que mejor discrimina entre los ejemplos de entrenamiento, el cual se obtiene mediante una propiedad estadística llamada *ganancia de información*. Después se añadirán al nodo raíz, otros nodos que corresponderán a los valores que puede tener este atributo. Este proceso se repite para cada uno de los nodos nuevos hasta haber analizado todos los atributos.

Para elegir los atributos que mejor clasifican dentro de todo el conjunto se usa la **ganancia de información** la cual está definida en términos de la **entropía**. La entropía es una medida muy usada en la teoría de información, la cual mide la incertidumbre de una variable aleatoria. Dada una colección S que contiene ejemplos positivos y negativo de una tarea, la entropía de S con respecto a la clasificación booleana es la siguiente [50]:

$$Entropy(S) \equiv -p_{\oplus} \log_2 p_{\oplus} - p_{\ominus} \log_2 p_{\ominus} \quad (2.6)$$

donde p_{\oplus} es la proporción de ejemplos positivos en S y p_{\ominus} es la proporción de ejemplos

negativos en S . La ganancia de información es la reducción esperada en la entropía causada por la partición de los ejemplos de acuerdo con este atributo [50]. La ganancia de información, $Gain(S, A)$ de un atributo A , en relación con un conjunto de ejemplos S , se define como:

$$Gain(S, A) \equiv Entropy(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} Entropy(S_v) \quad (2.7)$$

donde los valores de A es el conjunto de todos los valores posibles para el atributo A y S_v es el subconjunto de S para que el atributo A tenga un valor v por ejemplo:

$$S_v = \{s \in S \mid A(s) = v\} \quad (2.8)$$

Redes neuronales artificiales

Las redes neuronales artificiales (RNA) están basadas en la observación de los procesos biológicos que ocurren en el cerebro [50]. Están compuestas por nodos o unidades conectadas por vínculos dirigidos. Una conexión de la unidad i a la unidad j se encarga de propagar la activación a_i de i a la unidad j , cada conexión tiene un peso numérico $w_{i,j}$, asociado a él este determina la dirección e intensidad de la conexión. Cada nodo tiene una entrada con error $a_0 = 1$ con un peso asociado $w_{0,j}$. Cada unidad j calcula primero la suma de los pesos de sus entradas [44]:

$$in_j = \sum_{i=1}^n (w_{i,j} a_i) \quad (2.9)$$

Después se aplica una función de activación g de esta suma para obtener la salida:

$$a_j = g(in_j) = \sum_{i=0}^n (w_{i,j} a_i) \quad (2.10)$$

En la Figura 2.5, se puede observar un modelo simple de una neurona donde la activación de la unidad de salida está dada por: la activación como perceptrón o una función logística, también llamada función sigmoid, definida de la siguiente forma: una función

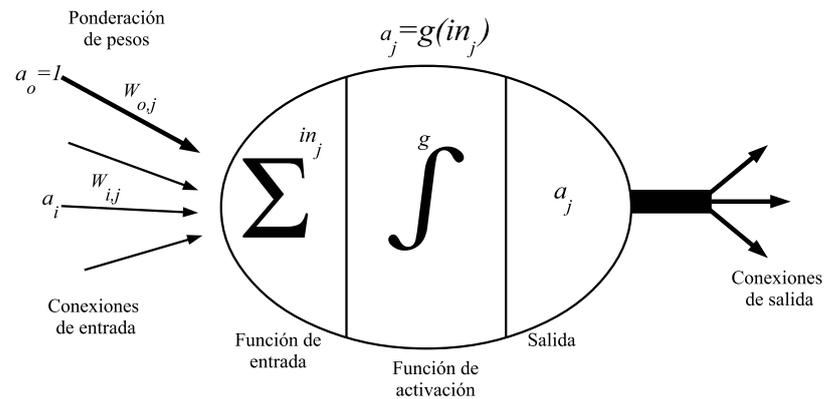


Figura 2.5: Modelo de una neurona.

g se puede ver como un umbral sólido, donde la unidad o nodo se conoce como [44, 50]:

$$f(x) = \frac{1}{1 + e^{-z}} \quad (2.11)$$

Las propiedades de las redes neuronales artificiales están determinadas por el tipo de topología y propiedades de las neuronas. Existen varios tipos de topologías para formar redes neuronales, entre ellas se pueden mencionar las de tipo *Feedforward* y las redes recurrentes. Las primeras tienen una sola dirección, es decir, la señal de entrada inicia en la capa de entrada hasta llegar a la salida sin formar ciclos y tienen una serie de capas: entrada, una o más ocultas y la de salida; la segunda es un tipo de red que puede formar diferentes topologías, se alimenta de sus propios resultados de sus entradas, puede formarse al menos un ciclo, la respuesta de red para una entrada depende de su estado inicial que puede depender de las entradas anteriores [44, 50].

El gradiente descendente proporciona la base para el algoritmo *backpropagation* y para otros métodos que deben buscar a través del espacio de hipótesis el cual tiene varios tipos de hipótesis continuamente parametrizados [50].

Una forma de calcular el error:

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in D} ((t_d - o_d)^2) \quad (2.12)$$

donde D es el conjunto de ejemplos de entrenamiento; t_d es la salida objetivo para los ejemplos de entrenamiento d ; o_d es salida de la unidad lineal para d .

El algoritmo *backpropagation* aprende de los pesos dada una red con un conjunto de unidades fijas y sus interconexiones. Hay un problema con el que se enfrenta este algoritmo, ya que debe buscar un espacio grande de hipótesis definida por todos los valores de pesos posibles para todas las unidades en la red; por lo que se apoya en el método gradiente descendente para minimizar el error cuadrado entre los valores de salida de la red y los valores objetivo para esas salidas [50].

Métodos basados en instancias

Los métodos basados en instancias almacenan todos los ejemplos de entrenamiento disponibles y posponen la clasificación de un dato nuevo hasta que éste sea presentado, debido a esto se les conoce como métodos “lazy”. Para hacer una nueva clasificación, el ejemplo nuevo se compara con los ejemplos previamente almacenados de tal manera que se puedan ordenar aquellos más parecidos y asignar el valor de la función para la instancia nueva [50]

El aprendizaje basado en instancias incluye a los métodos de vecinos más cercanos y regresión lineal localmente ponderada, que asumen instancias que pueden ser representadas como puntos en un espacio euclidiano [50]. La ventaja principal de este tipo de métodos es que el aprendizaje en lugar de estimar la función una vez para todo el espacio de la instancias, pueden estimarlo localmente y de manera diferente para cada

instancia nueva a clasificar.

El método más simple basado en instancias es el algoritmo de k -vecinos más cercanos (*K-Nearest Neighbor*). Este algoritmo asume todas las instancias de n que corresponden a los puntos en el espacio n -dimensional. Los vecinos más cercanos de una instancia están definidos en términos de la distancia euclidiana estándar [50].

Una instancia x arbitraria está descrita por el vector de características

$$(a_1(x), a_2(x), \dots, a_n(x))$$

donde $a_r(x)$, simboliza el valor del atributo r -ésimo de una instancia x . Por lo tanto, la distancia entre dos instancias x_i y x_j está definida como $d(x_i, x_j)$, por consiguiente se tiene la ecuación de la siguiente forma:

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (2.13)$$

El algoritmo de vecinos más cercanos es el siguiente [50]: durante el **entrenamiento** se almacenan los ejemplos $(x, f(x))$ para después realizar la **clasificación**, dado una nueva instancia x_q . Las $x_1 \dots x_k$, indican las instancias k de los ejemplos de entrenamiento más cercanos a x_q .

Teniendo lo siguiente:

$$\hat{f}(x_q) \leftarrow \operatorname{argmax}_{v \in V} \sum_{i=1}^k (\delta(v, f(x_i))) \quad (2.14)$$

donde, $f : \mathfrak{R}^n \rightarrow V$; (V es un conjunto finito v_1, \dots, v_s); (x_i) es la instancia de entrenamiento más cercana a x_q ; $\hat{f}(x_q)$, es el resultado obtenido de la estimación del valor más común de f entre los ejemplos de entrenamiento más cercanos k para x_q .

Naive Bayes

El teorema de *Bayes* proporciona una forma de calcular la probabilidad de una hipótesis basada en su probabilidad a priori, en las probabilidades de observar diferentes datos dada una hipótesis y de los datos observados por el mismo. El teorema de *Bayes* (ver ecuación 2.15), es la base de los métodos de aprendizaje bayesiano puesto que proporciona una manera de calcular la probabilidad posterior $P(h | D)$ de la probabilidad a priori $P(h)$, junto con $P(D)$ y $P(D | h)$ [50].

$$p(h | D) = \frac{P(D | h)P(h)}{P(D)} \quad (2.15)$$

donde, $P(h)$ indica la probabilidad a priori de h ; $P(D)$ es la probabilidad de D sin ningún conocimiento de h ; $P(D|h)$ es la probabilidad de D dado h . $P(h | D)$ es la probabilidad posterior de h .

Para calcular la hipótesis máxima posterior (*MAP*) h_{MAP} , se utiliza el teorema de *Bayes*, es decir:

$$h_{MAP} \equiv \operatorname{argmax}_{h \in H} P(h|D) = \operatorname{argmax}_{h \in H} \frac{P(D|h)P(h)}{P(D)} = \operatorname{argmax}_{h \in H} P(D|h)P(h) \quad (2.16)$$

En los casos donde las hipótesis son igual de probables a priori ($P(h_i) = P(h_j)$ para todas las h_i y h_j en H). Se puede calcular la hipótesis más probable donde sólo se va a considerar a $P(D|h)$, que es conocido como la probabilidad de los datos D dado h . La hipótesis que maximiza a $P(D|h)$ es llamado la hipótesis máxima probable (h_{ML}), la cual se obtiene de la forma siguiente [50]:

$$h_{ML} \equiv \operatorname{argmax}_{h \in H} P(D|h) \quad (2.17)$$

El algoritmo naive Bayes proporcionan una base para el aprendizaje de los métodos que trabajan directamente con probabilidades, también es una estructura para analizar el

funcionamiento de otros algoritmos que no utilizan probabilidad explícitamente [50].

Máquinas de vectores de soporte

Las máquinas de vectores de soporte (*Support Vector Machines, SVMs*), es un método de aprendizaje supervisado para realizar tareas de regresión, clasificación y detección [44].

SVMs calcula un hiperplano de separación óptimo para minimizar la norma cuadrada del hiperplano de separación. Esta minimización se puede ver como un problema de programación cuadrática convexa. Una vez calculado el hiperplano óptimo, los datos que se encuentran en este margen son conocidos como vectores de soporte y la solución se representa como una combinación lineal de esos vectores. El margen es la amplitud del área delimitada, es decir la distancia doble del separador al punto del ejemplo más cercano. *SVMs* es convexo y trabaja en un espacio de características inducido por kernels [22, 44].

Un hiperplano $w \cdot x + b = 0$, puede ser denotado como un par de (w, b) , donde, w es el vector de los pesos y b es el parámetro separado [44].

Si se considera un conjunto de entrenamiento

$$T = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$$

y S es el producto punto del espacio, donde

$$x_1, x_2, \dots, x_m \in S$$

para cualquier hiperplano en el espacio S , puede ser escrito como:

$$\{x \in S \mid w \cdot x + b = 0\}, w \in S, b \in R$$

El producto punto $w \cdot x$, está definido por:

$$w \cdot x = \sum_{i=1}^n (w_i x_i) \quad (2.18)$$

Existen dos casos a evaluar, cuando los datos son **linealmente separables** y cuando **no son linealmente separables**.

Es linealmente separable (ver Figura 2.6a) si existe al menos un clasificador lineal definido por el par (w, b) , los cuales clasifican correctamente a todos los ejemplos de entrenamiento. El hiperplano óptimo para este caso es la suma de las distancias de los ejemplos de entrenamientos más cercanos positivos y negativos [22, 44].

Y es linealmente no separable cuando no existe un hiperplano que separe exitosamente los datos negativos de los positivos en un conjunto de entrenamiento (ver Figura 2.6b). Una forma de resolver los linealmente no separables es mapear los datos a un espacio de alta dimensión (ver Figura 2.7) y definir un hiperplano que pueda separarlos. A este espacio de alta dimensión se le conoce como la espacio de características transformado [22, 44]. La función kernel se encarga de realizar la separación y traslado de los ejemplos al espacio de características, misma que se muestra a continuación [22, 44]:

$$K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j) \quad (2.19)$$

Existen diferentes tipos de kernels [3, 22]:

- **Lineal**

$$K(x_i, x_j) = x_i^T x_j$$

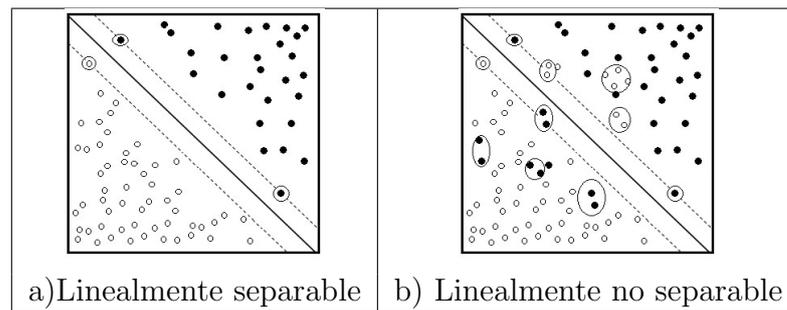


Figura 2.6: Ejemplos de los casos de SVMs

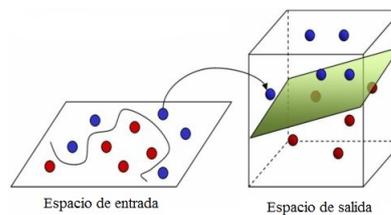


Figura 2.7: Ejemplo del mapeo de datos a una alta dimensionalidad.

- **Polinómica**

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$$

- **Gaussiana (RBF)**

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$$

2.5. Métricas de evaluación

Para evaluar el desempeño de la tarea de clasificación de cada uno de los algoritmos de aprendizaje automático, se usarán algunas métricas que nos permitirán comparar cada uno de ellos.

Matriz de confusión

Una matriz de confusión contiene información sobre la clasificación que se realizó usando

		PREDICCIÓN	
		Positivos	Negativos
ACTUAL	Positivos	TP	FP
	Negativos	FN	TN

Figura 2.8: Matriz de confusión

un algoritmo sobre un conjunto de datos, en cuya diagonal principal se indica el número de ejemplos clasificados correctamente para cada clase.

La matriz está formada de la siguiente manera (ver Figura 2.8) donde:

- **TP** (*True Positive*, verdaderos positivos) es el número de predicciones correctas de un ejemplo que es positivo.
- **FP** (*False Positive*, falso positivo) es el número de predicciones incorrectas de un ejemplo que es positivo.
- **TN** (*True Negative*, verdadero negativo) es el número de predicciones correctas de una instancia que es negativa.
- **FN** (*False Negative*, falso negativo) es el número de predicciones incorrectas de una instancia que es positiva.

De la matriz de confusión se obtienen las siguientes métricas de evaluación:

Exactitud (*Accuracy (AC)*) es el porcentaje entre el total de números de instancias correctamente clasificadas para todas las instancias del conjunto, la cual está determinada de la siguiente forma:

$$AC = \frac{TN + TP}{TN + FP + FN + TP} \quad (2.20)$$

Recuerdo (*Recall*) es la proporción de instancias correctas que actualmente pertenecen al subconjunto relevante y se calcula con la siguiente ecuación:

$$Recall = \frac{TP}{FN + TP} \quad (2.21)$$

Precisión (*Precision* (P)) es el número de instancias clasificadas como positivas según el criterio del algoritmo, la cual esta determinada por:

$$P = \frac{TP}{TP + FP} \quad (2.22)$$

Medida-F (*F-measure*) está métrica está basada en la precisión armónica, que combina el porcentaje de *precision* y *recall*, y se obtiene con la siguiente ecuación:

$$F - measure = 2 \cdot \frac{P \cdot Recall}{P + Recall} \quad (2.23)$$

Sensibilidad (*sensitivity*) es el porcentaje de instancias verdaderas positivas que son clasificados correctamente y se obtiene de la forma siguiente:

$$sensitivity = \frac{TP}{TP + FN} \quad (2.24)$$

Especificidad (*specificity*) es el porcentaje de ejemplos verdaderos negativos que son clasificados correctamente y es calculada con la ecuación siguiente:

$$Specificity = \frac{TN}{TN + FP} \quad (2.25)$$

El área bajo la curva ROC es considerada como la más exacta y la medida global del rendimiento de un sistema. Un área de 1,0 tiene una *sensibilidad* = *especificidad* = 1 y representa una clasificación o detección perfecta. Mientras que el área de 0,5 representa el rendimiento de un sistema sin valor es decir su eficiencia es al azar.

2.6. Estado del arte

En esta sección se describen algunos trabajos en el ámbito médico, que han utilizado algoritmos de aprendizaje automático y procesamiento de imágenes. Actualmente las

técnicas de aprendizaje automático se aplican en diversas áreas de la medicina para el reconocimiento, clasificación o detección de diferentes enfermedades.

Aplicaciones para enfermedades de los ojos

En las Tablas 2.2 y 2.3, se resume los diversos trabajos realizados para la clasificación o detección de enfermedades de los ojos.

Aplicaciones médicas en general

En la Tabla 2.4, se muestran algunos trabajos elaborados, para la identificación, clasificación y diagnóstico de diversas enfermedades.

2.6.1. Discusión

En este trabajo se utilizará un conjunto de algoritmos de aprendizaje automático para la clasificación de dos clases de retinopatía diabética, proliferativa y no proliferativa, además tiene una estrecha relación con el procesamiento de imágenes, porque se aplicarán algunas técnicas para eliminar el ruido y resaltar algunas características para obtener mejores resultados en la tarea de clasificación. Para la reducción y extracción de características de las imágenes de fondo de ojo de este trabajo, se utilizará los métodos de *PCA* y redes neuronales. La red neuronal como método de reducción y caracterización de imágenes no es muy usado, debido a que generalmente las redes neuronales se utilizan para las tareas de clasificación o detección, por esta razón en este trabajo se usarán para después realizar una comparación con el método de *PCA* y así poder analizar el desempeño que tiene la red neuronal en la tarea de reducción y caracterización.

Tabla 2.2: Trabajos relacionados

Autor	Propuesta de clasificación o detección	Algoritmos de preprocesamiento y caracterización	Algoritmos de clasificación	Conjunto de datos	Métricas de evaluación	Resultados
Niemeijer M. et al [34]	exudados duros y suaves	Filtros Gaussianos	k-vecinos más cercanos	130 imágenes 1048x1536 1024x768 píxeles	área bajo la curva ROC (especificidad, sensibilidad)	0.95 %
Sopharak A. et al [5]	exudados no exudados	Escala de grises filtrado medio equalización de histograma de adaptación de contraste limitado	naive Bayes SVMs	39 imágenes 760x570 píxeles	sensibilidad especificidad precisión accuracy	92.28 % 98.52 % 53.05 % 98.41 %
Karegowda A. et al [2]	exudados no exudados	Conversión del espacio de color HSI, filtro medio, equalización del histograma de adaptación	Red neuronal	89 imágenes 1500x1152 accuracy	sensibilidad especificidad 100 % 98.45 %	96.97 %
Silberman N. et al [32]	exudados disco óptico	Balance global de color, aumento de luminosidad filtros personalizados, conversión a escala de grises	SVMs	1000 imágenes	accuracy	98.40 %
Sopharak A. et al [49]	exudados no exudados	Técnica de morfología matemática, Fuzzy C-Means Clustering	naive Bayes, SVMs k-vecinos más cercanos	60 imágenes 752x500 píxeles	sensibilidad especificidad precisión accuracy	NB 93.38 %, SVMs 92.28 % naive Bayes 98.14 %, SVMs 98.54 % NB 47.51 %, SVMs 53.03 % NB 98.05 %, SVMs 98.41 %

Tabla 2.3: Trabajos relacionados

Autor	Propuesta de clasificación o detección	Algoritmos de preprocesamiento y caracterización	Algoritmos de clasificación	Conjunto de datos	Métricas de evaluación	Resultados
Englmeier K.H et al [25]	venas arterias	Filtro Gaussiano	Análisis discriminante	60 imágenes 760x570 pixeles	accuracy	venas 66.5 % arterias 78.4 %
Kavitha S. and duraiswamy K. [42]	exudados duros y suaves	Conversión del espacio de color	binarización, morfología matemática	Base de datos de DIARETBDB1	sensibilidad especificidad	89.78 % 99.21 %
Osareh A. et al [4]	exudado no exudados	Fuzzy c-means Clustering, especificación de histograma, mejora de contraste local	Red neuronal, k-vecinos más cercanos, clasificador gaussiano cuadrático regla delta lineal	60 imágenes 760x570 pixeles	sensitividad sensibilidad accuracy	93.4 % 82.7 % 90.1 %
Osareh A. et al [12]	exudados no exudados	normalización de color, mejora de contraste, Fuzzy c-means clustering	Red neuronal	40 imágenes 760x570 pixeles	sensibilidad sensitividad	92 % 82 %

Tabla 2.4: Aplicaciones médicas en general

Autor	Propuesta	Algoritmos utilizados	Resultados
<i>Zhou Z. et al</i> [56]	Identificación de cáncer de pulmón	Ensamble de redes neuronales	2.5% de error en falsos negativos
<i>Sharkey A. et al</i> [47]	Detección de cáncer de mama	Ensamble de redes neuronales	94.81 % de sensibilidad
<i>Jesneck J. et al</i> [23]	Diagnosticar lesiones de mama	Red neuronal, análisis discriminante lineal	92% de sensibilidad, especificidad y ± 0.02 como desviación estándar medido bajo la curva de ROC
<i>Zheng J. et al</i> [21]	Compresión de imágenes de mastografías	<i>PCA</i> , <i>k-nn</i> y la técnica llamada <i>JPEG2000</i>	80:1 de porcentaje de compresión usando <i>JPEG2000</i>
<i>Joshi S. et al</i> [41]	Clasificación de Alzheimer, parkinson y enfermedades vasculares	Árboles de decisión, redes neuronales artificiales	99.3% de <i>accuracy</i>
<i>Fan Y. et al</i> [55]	Identificación de anomalías en el cerebro	<i>SVMs</i>	91.8% de <i>accuracy</i>
<i>Christodoulou C.I. et al</i> [8]	Clasificación de imágenes de ultrasonido de la placa carótida	<i>k-nn</i> y <i>SOM</i> (<i>self organizing map</i>)	72.6% para <i>SOM</i> y 73% para <i>k-nn</i> de <i>accuracy</i>

La diferencia de este trabajo con los trabajos relacionados, es que ellos utilizaron el método de análisis lineal discriminante o filtros gaussianos para la extracción de características y solo clasifican o detectan una o varias características de la retinopatía diabética como son exudados blandos o duros, hemorragias entre otros, mientras que en este trabajo se clasificará la enfermedad en su totalidad como proliferativa y no proliferativa.

Capítulo 3

Método automático de clasificación

3.1. Método propuesto para clasificar las imágenes de la retinopatía diabética

El siguiente método es propuesto para clasificar imágenes de fondo de ojo en dos tipos de retinopatía diabética: proliferativa y no proliferativa. Este método consiste en tres fases: 1) procesamiento de imágenes; 2) reducción y caracterización de las imágenes usando los métodos de *PCA* y redes neuronales de Hinton; 3) Clasificación de las imágenes en RDNP y RDP usando algoritmos de aprendizaje automático como: árboles de decisión, k -vecinos más cercanos, naive Bayes, redes neuronales artificiales y máquinas de vectores de soporte (*SVMs*). La Figura 3.1 muestra el método de forma general, el cual opera de la siguiente manera:

Dado un conjunto de imágenes de fondo de ojo, primero se les aplica diferentes técnicas de procesamiento de imágenes para mejorar y realzar las características de cada una de ellas, después se reduce la dimensionalidad y se extrae las principales características de las imágenes y como último paso, se realiza la clasificación en dos tipos RDNP y RDP, usando algunos algoritmos de aprendizaje automático.

En las siguientes secciones se explica a detalle cada una de las etapas.

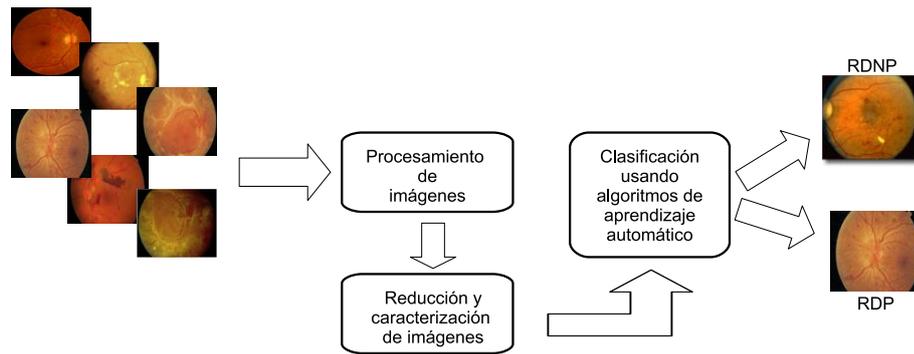


Figura 3.1: Etapas del método propuesto para clasificar imágenes de retinopatía diabética

3.2. Procesamiento de imágenes

En esta fase se aplicaron varias técnicas de procesamiento de imágenes al conjunto de imágenes de fondo de ojo aplicando las siguientes técnicas de procesamiento: detector de bordes *Canny*, rango del filtro (*range-filter*), ecualización del histograma y binarización que fueron descritos en la Sección 2.2.

3.3. Reducción y caracterización de imágenes

El propósito de reducir la dimensionalidad de las imágenes de fondo de ojo y extraer sus principales características, para facilitar la manipulación de cada una de ellas con un mínimo de pérdida de información, esto contribuye a la disminución en el poder computacional, tiempo de ejecución para la tarea de clasificación o para alguna otra, además se reduciría el espacio de almacenamiento de toda la información. Ya que trabajar con el conjunto de imágenes original, consumiría mucho tiempo para realizar alguna tarea y esto implica una demora en la toma de decisiones.

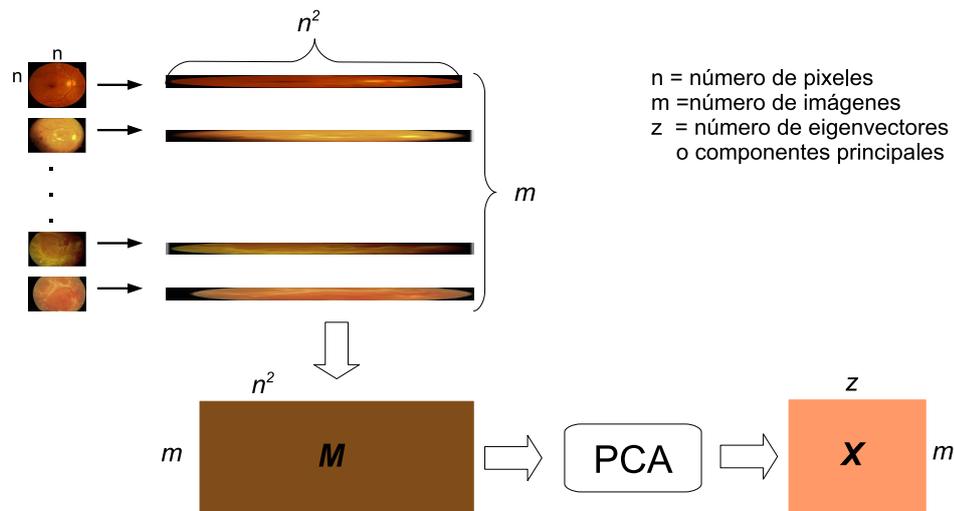


Figura 3.2: Fase de reducción y caracterización de imágenes con *PCA*

En esta fase se usaron dos métodos, el método de *PCA* y la red neuronal de Hinton, que a continuación se detalla la forma de operar para cada uno de ellos.

3.3.1. Análisis de componentes principales

El método de *PCA* descrito en la Sección 2.3.1 opera de la siguiente manera, la cual se muestra en la Figura 3.2. El primer paso es transformar cada imagen en un vector para obtener una matriz M de tamaño n -número de imágenes por n -píxeles, después se aplica el método de *PCA* a la matriz M , de la cual se obtendrán los n -eigenvectores o n -componentes principales que mejor reporten para la distribución de todo el conjunto de imágenes. Estos valores obtenidos forman la matriz X cuyo tamaño es de n -imágenes por n -componentes principales.

Para obtener los atributos que serán usados en la fase de clasificación, se realiza una

proyección de las imágenes originales sobre los eigenvectores.

$$Proj = z' * M \quad (3.1)$$

donde z son los eigenvectores y M las imágenes originales.

3.3.2. Modelo de la red neuronal de Hinton

La reducción y caracterización de imágenes con el método de la red neuronal de Hinton, explicado en la sección 2.3.2, cuya forma de operar se muestra en la Figura 3.3, que consiste de la siguiente manera: dado un conjunto de imágenes se transforman en vectores para así obtener una matriz de tamaño n -número de imágenes por n -píxeles, llamada matriz original, enseguida se inicializa la etapa de pre-entrenamiento para obtener los pesos adecuados, que serán los valores iniciales del sistema *autoencoder* (codificación y decodificación), el cual es ejecutado inmediatamente y finalmente pasa a la etapa de ajuste, en este paso se aplica nuevamente el sistema *autoencoder*, el cual se repite n -veces hasta obtener el resultado deseado, en este caso una imagen similar a la original. El proceso de este sistema es el siguiente: toma la matriz original y en cada capa la reduce a un tamaño que anteriormente se le ha indicado, lo que se reduce es el número de píxeles, los cuales son etiquetados como características.

La última capa del sistema *autoencoder* (Figura 3.3, capa 4), es la que proporciona los atributos de entrada para los algoritmos que llevarán a cabo la clasificación.

Para trabajar con la red neuronal de Hinton y elegir los valores adecuados que obtengan mejores resultados se realizó lo siguiente:

1. Se modifico la forma de leer las imágenes, ya que originalmente la red neuronal de Hinton recibe imágenes binarias
2. Se realizaron aproximadamente 20 experimentos con los valores por default de la

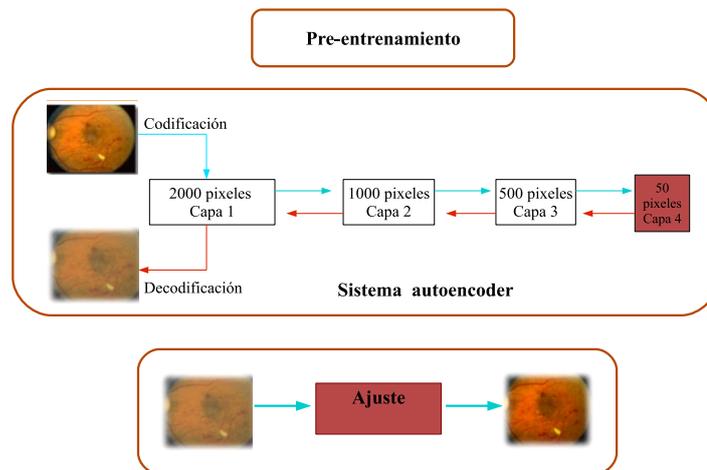


Figura 3.3: Fase de reducción y caracterización de imágenes con la red neuronal de Hinton

red neuronal.

3. Se manipulo las capas de la red neuronal para realizar diferentes experimentos con el propósito de obtener los mejores resultados. La red neuronal de Hinton por default trabaja con 4 capas, así que se disminuyo a 3 y después se aumento a 5 y 6 capas.
4. Se vario los valores por default de la red neuronal, realizando aproximadamente 50 experimentos.

3.4. Clasificación usando algoritmos de aprendizaje automático

En esta fase se usaron los algoritmos que se describieron en la Sección 2.4.2. La Figura 3.4 muestra la operación de la clasificación.

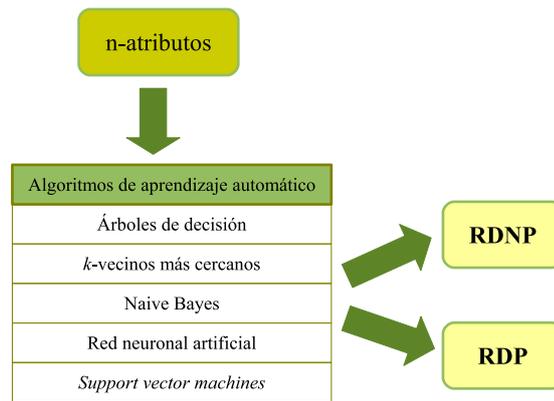


Figura 3.4: Fase de clasificación usando algoritmos de aprendizaje automático

Los atributos de entrada que se usaron para cada uno de los algoritmos son los resultados obtenidos de la proyección de los eigenvectores obtenidos con el método de *PCA* y las características obtenidas con la red neuronal de Hinton.

Capítulo 4

Resultados Experimentales

4.1. Datos

Los experimentos fueron realizados con un conjunto de 151 imágenes de fondo de ojo de 2588×1958 pixeles, etiquetado como $S3$. Estas imágenes fueron clasificadas manualmente por un retinologo; 109 como RDNP que será la clase 1 y 42 como RDP llamada clase 2.

Para probar el método propuesto y realizar los experimentos, del conjunto original se realizaron varios subconjuntos, primero por número de imágenes ($S1, S2, S3$) y después de cada conjunto resultante se obtuvieron otros por tamaño de resolución ($R1, R2, R3$), los conjuntos resultantes se muestran en la Figura 4.1. El conjunto $S1$ tiene 21 imágenes por clase y el conjunto $S2$, 42 por clase.

4.2. Clasificación y evaluación

Para la fase de clasificación se ejecutaron los algoritmos de aprendizaje automático como árboles de decisión (AD), k -vecinos más cercanos (k -nn), naive Bayes (NB), redes

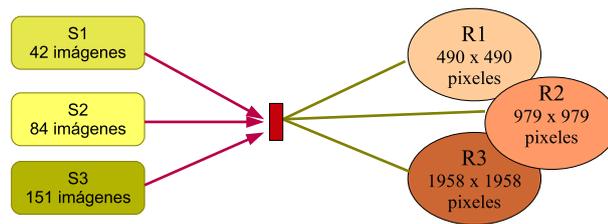


Figura 4.1: Conjuntos para el método de *PCA*

neuronales (RN) y máquinas de vectores de soporte (*SVMs*) que están implementados en el software *Weka*. Para todos los experimentos se usó *10-fold cross-validation* y para evaluar el desempeño de cada uno de ellos se usaron las siguientes métricas *accuracy*, *precision*, *recall* y *F-measure*, que fueron descritas en la Sección 2.5

La clasificación se realizó primero con los valores por default para cada algoritmo y después modificando algunos valores, para ambos se iteró la semilla en cada corrida. La modificación de los valores se realizó con el objetivo de comprobar si existe alguna mejora.

A continuación se reportan los resultados para cada una de las etapas del método propuesto, donde además se realizaron experimentos con imágenes sin procesamiento para comparar los resultados con las imágenes procesadas en la clasificación.

4.3. Resultados procesamiento de las imágenes

Las técnicas de procesamiento de imágenes fueron: detector de bordes *Canny*, ecualización del histograma, (*range-filter*) y binarización. Estas técnicas se encuentran implementadas en el software de Matlab. Para cada uno de ellos se usaron parámetros por default, con excepción de la técnica de binarización, que usó el nivel de umbral

otsu. Las Figuras 4.5: a), b), c), d) y e) muestran los resultados obtenidos de cada una de la técnicas de procesamiento de imágenes.

4.4. Resultados de la reducción, caracterización y clasificación

4.4.1. Resultados con el método de PCA

Con el método de PCA se obtuvieron aquellos componentes principales que representarán el 80 %, 85 % y 90 % de información relevante para cada conjunto de imágenes, también se experimento con un componente principal que representa entre el 50 %-60 % de información. En la Figura 4.2, se muestra la relación entre la varianza acumulada y el número de componentes principales para los conjuntos con imágenes sin procesamiento, donde se puede observar que existe una similitud entre los conjuntos, ya que para obtener el 90 % de información se uso casi el mismo número de componentes principales.

Para los conjuntos con técnicas de procesamiento, los resultados de la relación entre la varianza acumulada y el número de componentes principales se muestra en las Figuras 4.3 y 4.4, aquí se puede observar que para cada técnica el número de componentes es muy variable, como *Canny* que para el conjunto de *S2* imágenes se usaron aproximadamente 60 componentes principales para los tres tamaños de resolución, mientras que para el conjunto de *S3* imágenes se usaron alrededor de 100 componentes principales en los tres tamaños de resolución para obtener el 90 % de información. Este comportamiento se presenta para las técnicas restantes, en comparación con las imágenes sin procesamiento donde la diferencia entre conjuntos fue de 1 ó 2 componentes principales.

En todas las relaciones se observa un comportamiento similar entre los tres tamaños de resolución, donde existe apenas un mínimo de componentes principales para la obten-

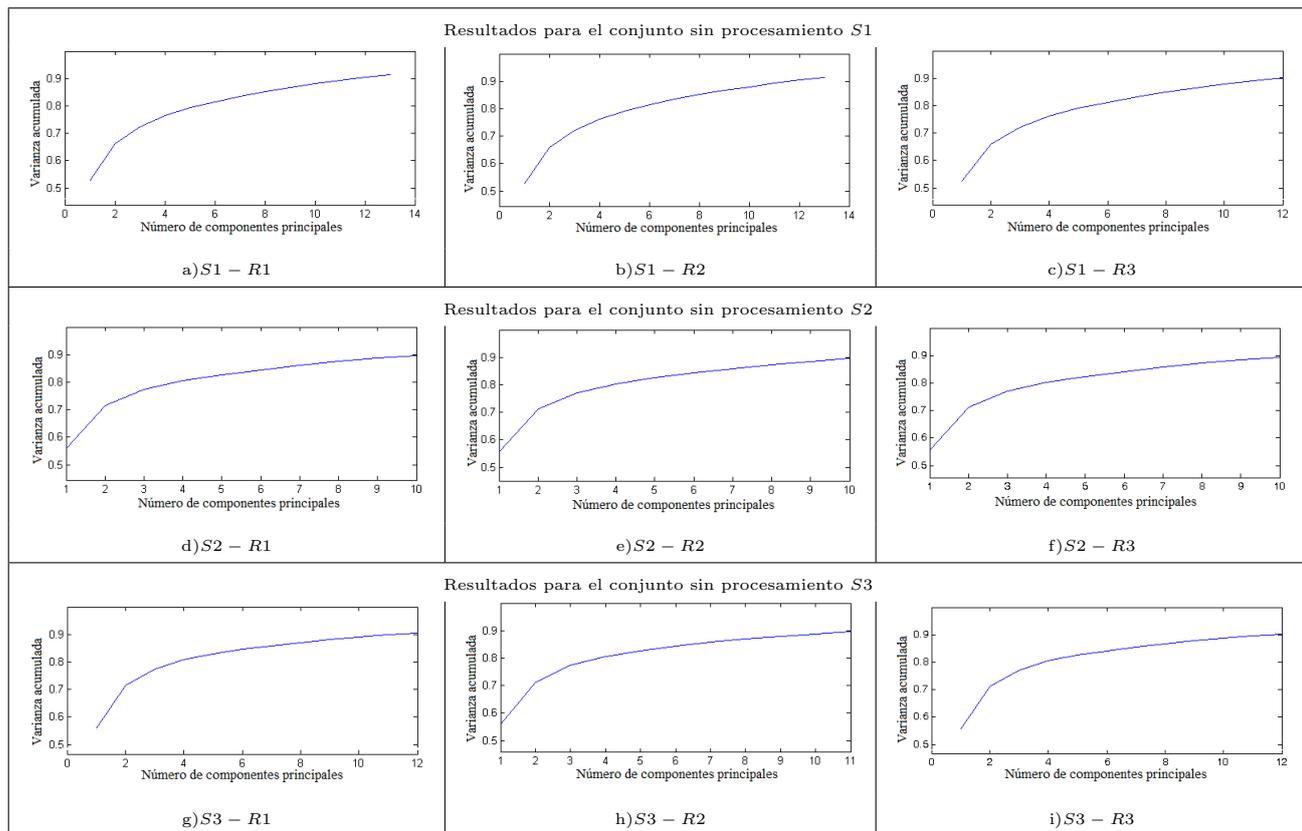


Figura 4.2: Relación entre la varianza acumulada y el número de componentes principales.

er el mismo porcentaje de información, esto nos indica que aún usando una imagen de resolución menor se puede obtener la misma cantidad de información con el mismo número de componentes principales que con el tamaño de resolución mayor. Estos resultados son útiles porque nos muestran que se puede trabajar con una imagen de resolución menor sin arriesgar pérdida de información y además disminuir el poder computacional y tiempo de ejecución. En las Figuras 4.5: f), g), h), i), j) se observan las reconstrucciones obtenidas para el conjunto de $S2$ imágenes y en las Figuras 4.5: k), l), m), n), o) para el conjunto $S3$. Como se puede observar todas las reconstrucciones fueron casi similares a la imagen original. Los resultados de la clasificación, son el promedio de 10 corridas.

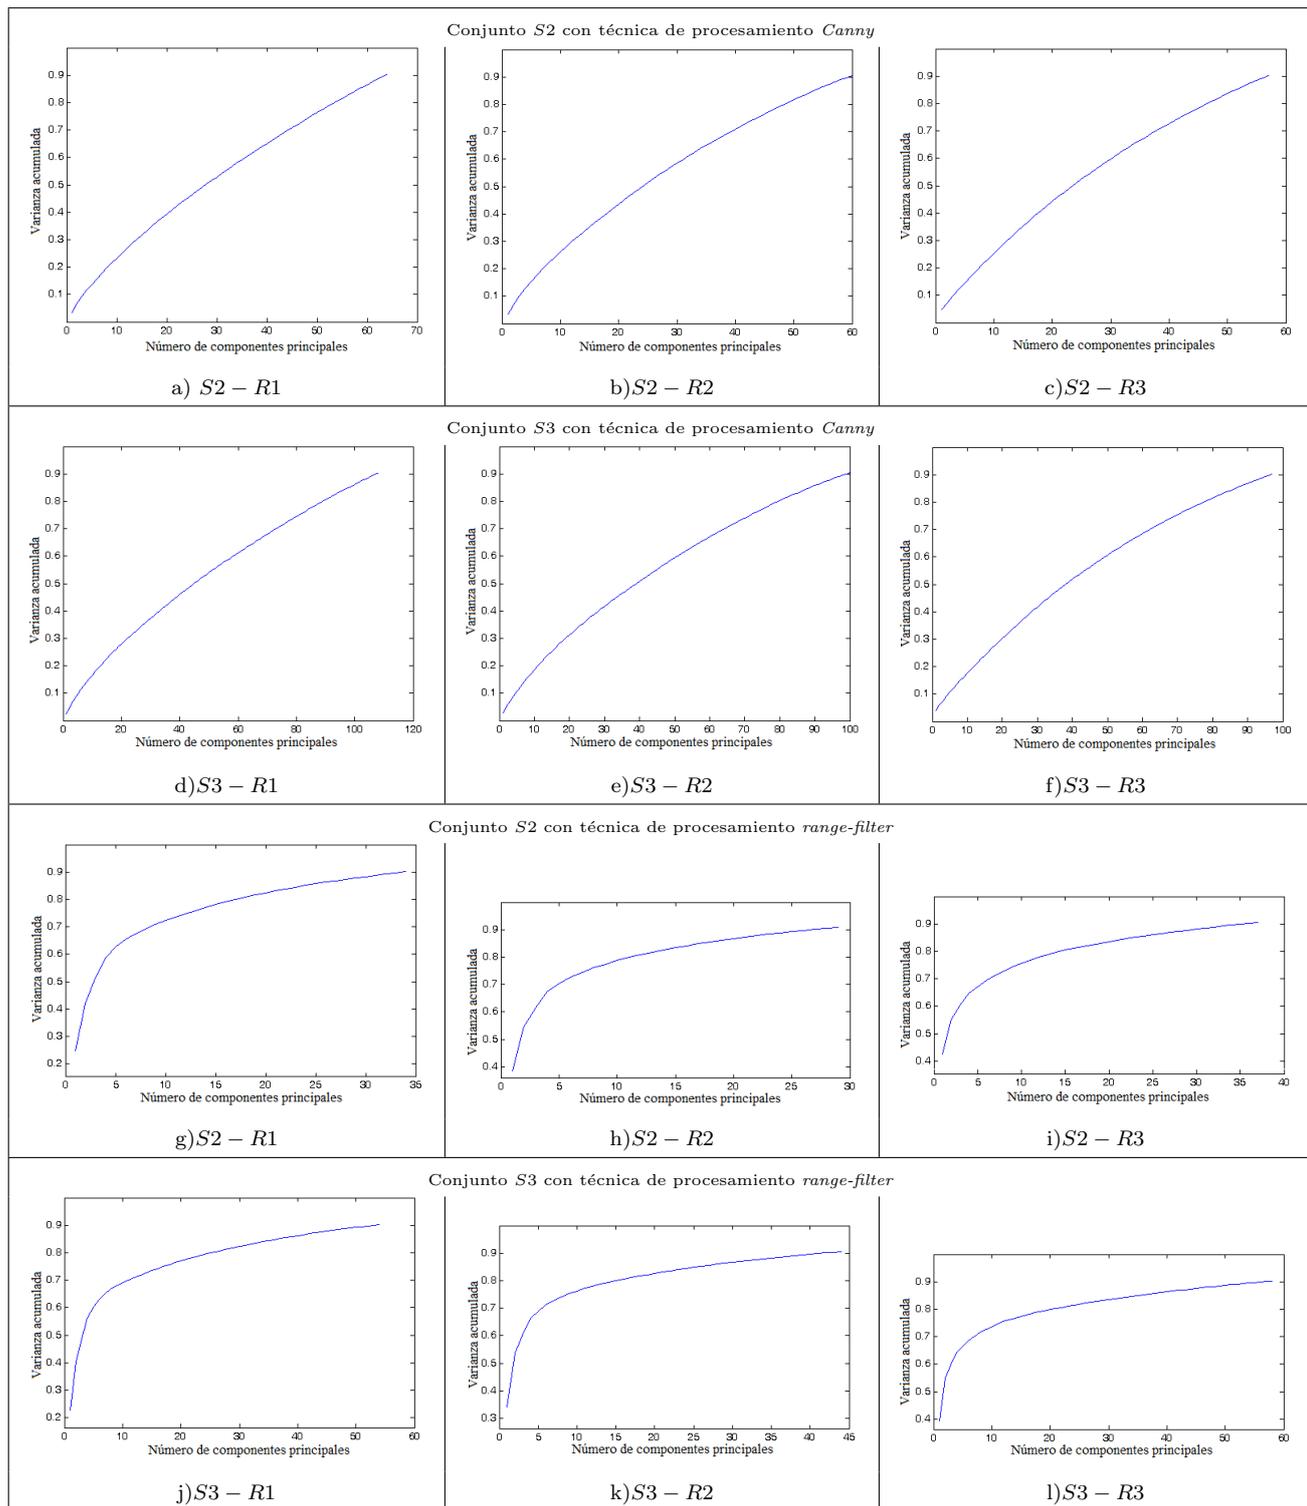


Figura 4.3: Relación entre la varianza acumulada y el número de componentes principales.

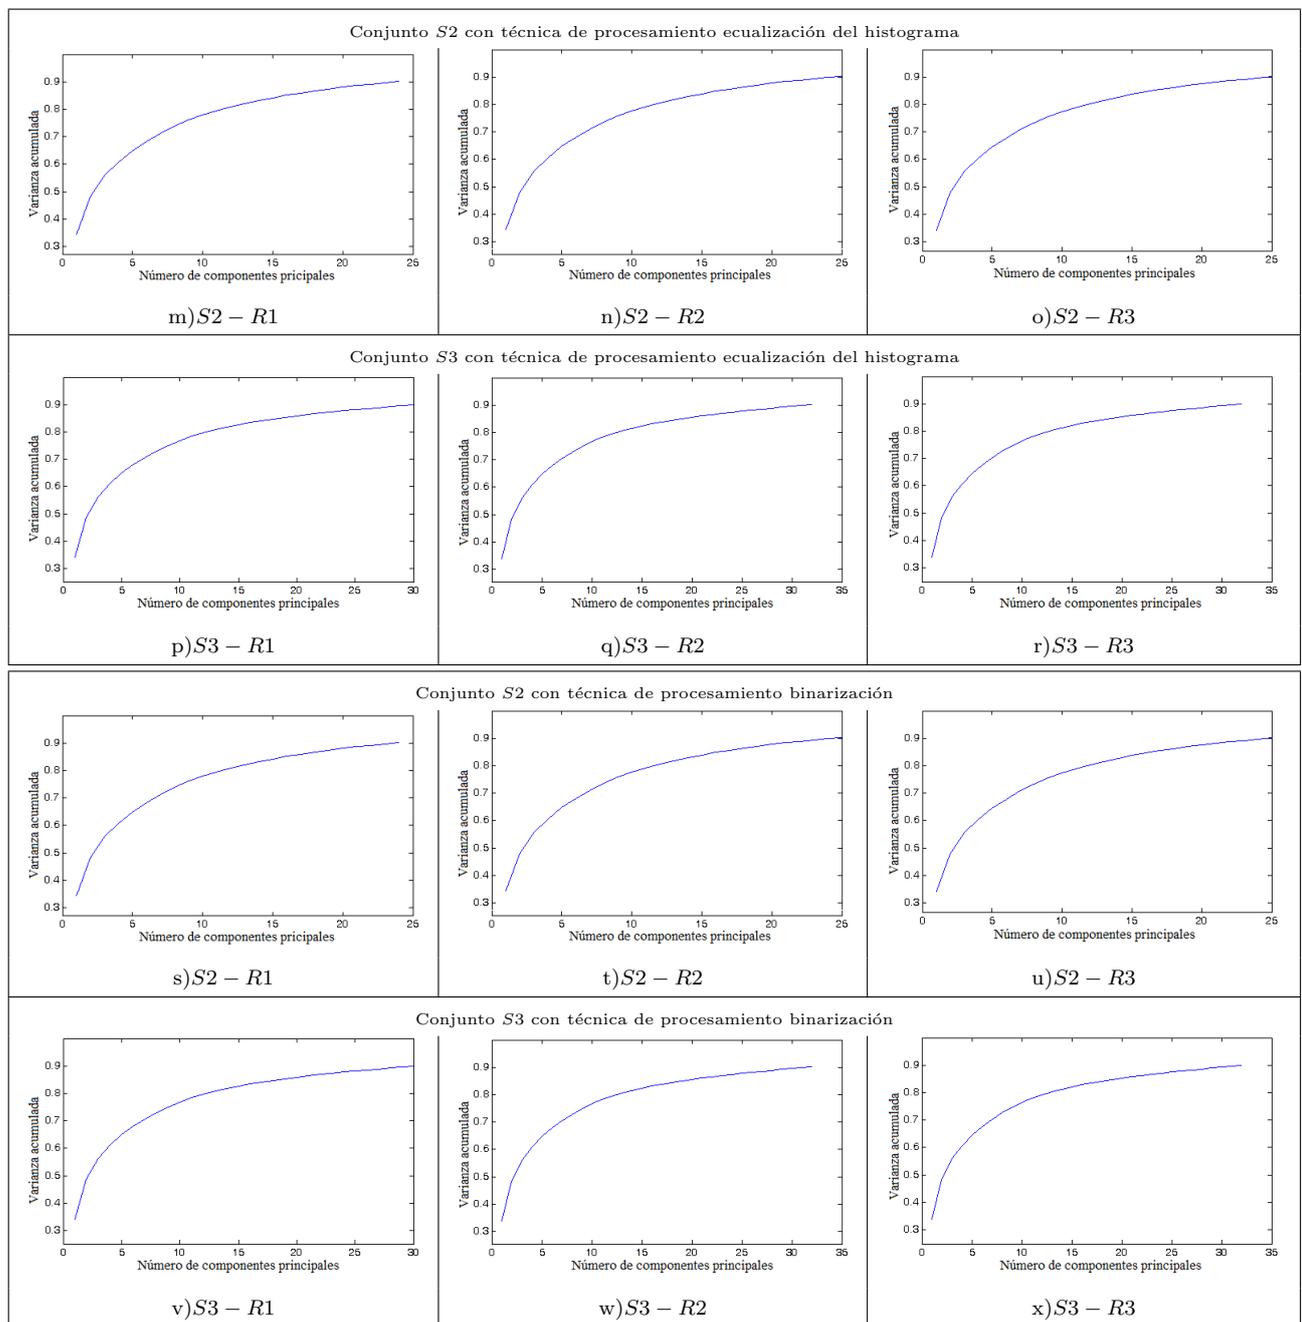


Figura 4.4: Relación entre la varianza acumulada y el número de componentes principales.

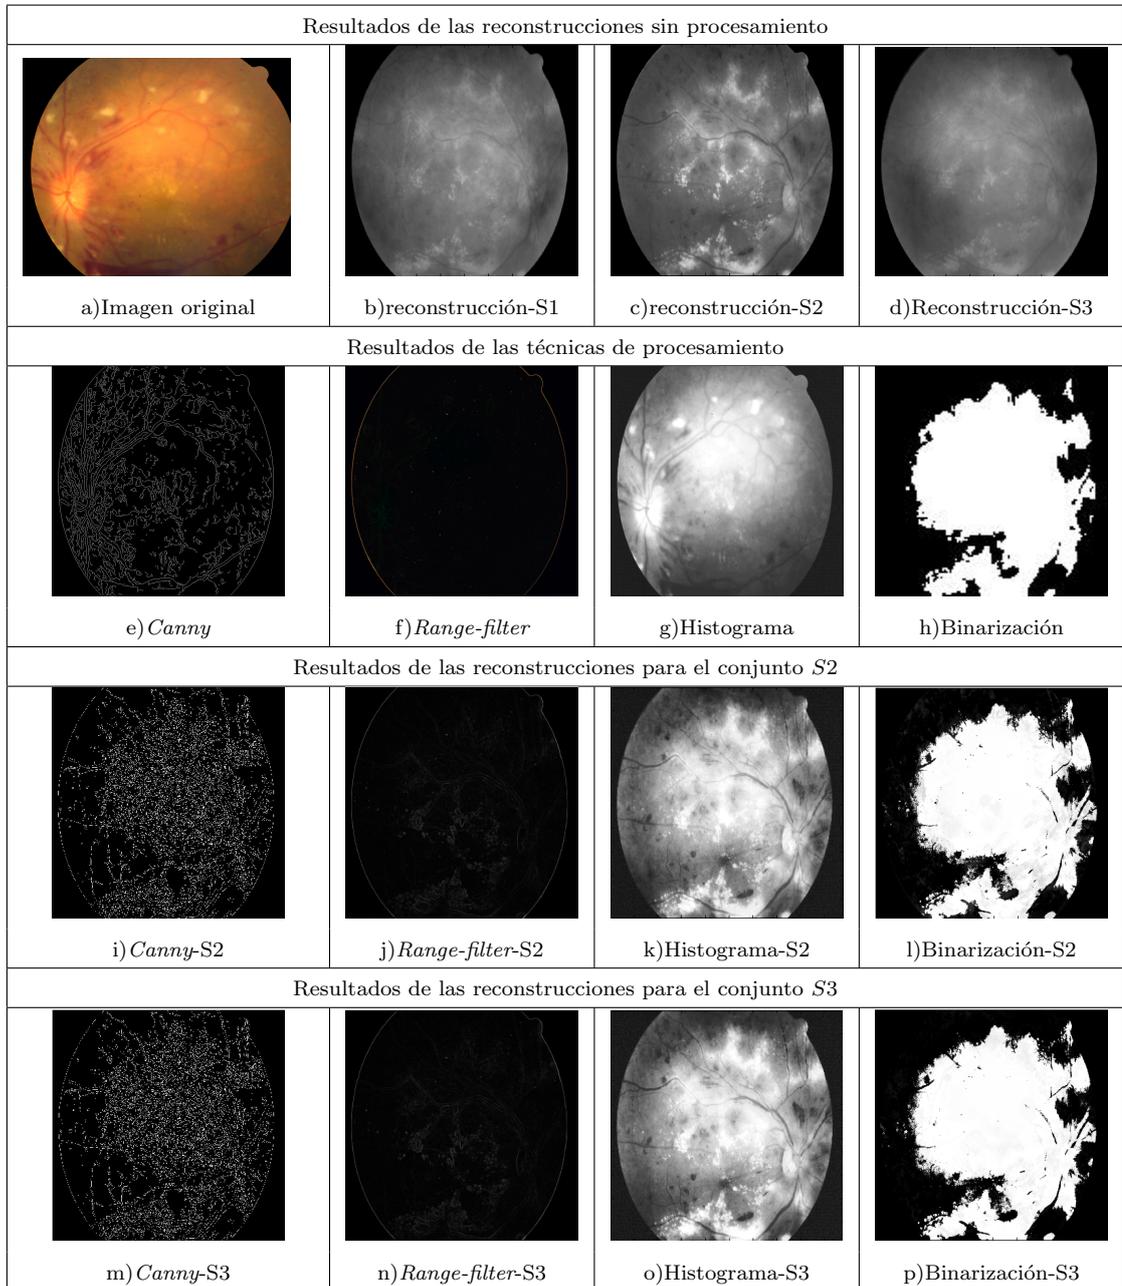


Figura 4.5: Resultados de las técnicas de procesamiento y reconstrucciones.

Resultados de la clasificación con imágenes sin procesamiento

Las Tablas 4.1, 4.2 y 4.3 muestran los resultados con imágenes originales, estos experimentos fueron realizados con los parámetros por default.

El mejor resultado del conjunto $S1$ fue obtenido con el algoritmo k -nn con 73,3% de *precision* con el tamaño de resolución 979×979 usando 5 componentes principales que representa el 80% de información; árboles de decisión obtuvo el resultado para el conjunto $S2$ con 61,1% de *precision* con un tamaño de resolución de 1958×1958 , utilizando 5 componentes principales que representa el 80% de información y para el conjunto $S3$ los mejores resultados fueron de 73,4% con las métricas *accuracy* y *recall* obtenidos con el algoritmo naive Bayes, con el tamaño de resolución de 1958×1958 con 8 componentes principales equivalente al 85% de información.

Los resultados de la clasificación con los parámetros modificados para las imágenes originales se muestran en las Tablas 4.4, 4.5 y 4.6. El mejor resultado del conjunto $S1$ es obtenido con el algoritmo k -nn con 75,2% de *precision* con el tamaño de resolución de 979×979 usando 5 componentes principales que representa el 80% de información, los parámetros que se modificaron fueron: $KNN = 1$, *nearestNeighbourSearchAlgoritm* = *BallTree* y *distanceFunction* = *LinearNNSearch*; el conjuntos $S2$ obtuvo 66,2% de *precision* como mejor resultado con k -nn 7 que representan el 85% de información, con un tamaño de resolución de 979×979 , los parámetros modificados fueron: $KNN = 5$, *nearestNeighbourSearchAlgoritm* = *LinearNNSearch* y *distanceFunction* = *EuclideanDistance* y el conjunto $S3$ obtuvo 80,3% de *precision* usando 1 componente principal para los 3 tamaños de resolución con el algoritmo naive Bayes, los parámetros modificados fueron: *useKernelEstimator* = *true* y *useSupervisedDiscretization* = *false*.

Tabla 4.1: Promedios % de las métricas para el conjunto S1, con parámetros por default.

Escala	R1				R2				R3			
% Información relevante	53 %	80 %	85 %	90 %	53 %	80 %	85 %	90 %	53 %	80 %	85 %	90 %
n -PCs	1	5	7	10	1	4	7	10	1	4	6	10
<i>Accuracy</i>												
AD	47.6	41.4	48.1	51.2	47.4	45.2	45.5	50.2	47.6	40.7	50.2	49.5
k -nn	41.9	67.2	58.3	59.5	46.7	73.1	57.8	59	47.6	65.9	57.6	61.9
NB	55.5	56.2	65	58.3	56.9	66.7	50.5	59	57.1	56.7	61.4	63.6
RN	56.2	61.2	59.5	57.9	56.9	57.1	58.1	59.3	56.4	62.4	63.1	59.5
SVMs	52.9	54.8	63.1	60.7	54	58.3	54.1	59.3	54.5	53.3	63.6	58.6
<i>Precision</i>												
AD	44.3	41.1	48	51.2	44.1	45.1	44.9	50.2	44.3	40.3	49.9	49.5
k -nn	41.9	67.2	59.7	60.7	46.6	73.3	58.1	60.1	47.6	66	58.8	63.7
NB	56.3	56.2	65	58.5	58.1	66.7	50.5	59.3	58.5	56.7	61.5	63.7
RN	56.3	61.4	59.7	58.1	57.1	57.1	58.2	59.4	56.6	62.6	63.4	59.7
SVMs	53	54.8	63.2	61.2	54.4	58.4	54.1	59.5	54.9	53.4	63.7	58.8
<i>Recall</i>												
AD	47.6	41.4	48.1	51.2	47.4	45.2	45.5	50.2	47.6	40.7	50.2	49.5
k -nn	41.9	67.2	58.3	59.5	46.7	73.1	57.8	59	47.6	65.9	57.6	61.9
NB	55.5	56.2	65	58.3	56.9	66.7	50.5	59	57.1	56.7	61.4	63.6
RN	56.2	61.2	59.5	57.9	56.9	57.1	58.1	59.3	56.4	62.4	63.1	59.5
SVMs	52.9	54.8	63.1	60.7	54	58.3	54.1	59.3	54.5	53.3	63.6	58.6
<i>F-measure</i>												
AD	38.7	40.9	47.7	50.8	38.8	45	44.4	50	38.7	40.1	49.7	49.2
k -nn	41.8	67.1	56.9	58.4	46.6	73.1	57.4	58	47.5	65.9	56.2	60.6
NB	54.1	56.1	65	58.1	55.3	66.7	49.8	58.7	55.5	56.6	61.4	63.5
RN	55.9	61	59.3	57.6	56.6	57.1	57.9	8.9	56.1	62.2	62.9	59.3
SVMs	52.4	54.6	63	60.4	53.7	58.3	54	59	53.8	53.2	63.5	58.2

Tabla 4.2: Promedios % de las métricas para el conjunto S2, con parámetros por default.

Escala	R1				R2				R3			
% Información relevante	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %
n -PCs	1	6	9	13	1	5	8	13	1	6	9	12
<i>Accuracy</i>												
AD	47.6	47	51.8	48.7	47.7	47.2	53.1	48.7	47.4	52.8	53.1	48.3
k -nn	51.1	48.2	58.1	52	53.6	47.2	57.5	51.6	53.6	58.1	58	51.6
NB	46.9	48.8	49.2	59.9	47.9	49.4	52.3	58.7	45.4	44.4	50	57
RN	46.2	56	52.4	53.5	47.4	56.2	52.3	53.7	41.7	53.7	51.9	55
SVMs	46.5	51.8	49.9	57	47.4	50	46.5	59.3	46.5	51.8	47.6	58.7
<i>Precision</i>												
AD	46.5	46	56.2	48.2	46.3	46.2	59.5	48.7	46.3	61	60.7	47.5
k -nn	51.1	48.2	58.1	52	53.6	47.2	57.5	51.6	53.6	58.2	58	51.6
NB	46.5	48.8	49.2	60	47.7	49.4	52.3	58.8	44.7	44.4	50	57.1
RN	46.1	56	52.4	53.5	46.7	56.3	52.3	53.8	46.8	53.8	51.9	54.9
SVMs	46.3	51.8	49.9	57.2	47.1	50	46.8	59.6	46.4	51.8	47.6	58.9
<i>Recall</i>												
AD	47.6	47	51.8	48.7	47.4	47.2	53.1	48.7	47.4	52.8	53.1	48.3
k -nn	51.1	48.2	58.1	52	53.6	47.2	57.5	51.6	53.6	58.1	58	51.6
NB	46.9	48.8	49.2	59.9	47.9	49.4	52.3	58.7	45.4	44.4	50	57
RN	46.2	56	52.4	53.5	47.4	56.2	52.3	53.7	47.1	53.7	51.9	54.9
SVMs	46.5	51.8	49.9	57	47.4	50	46.9	59.3	46.5	51.8	47.6	58.7
<i>F-measure</i>												
AD	43	43	43.6	43.6	43	43.1	45.3	42.5	43	43.1	44	43.1
k -nn	51	48	58.1	51.9	53.5	47.1	57.5	51.5	53.5	58	58	51.4
NB	45	48.5	49	59.8	45.8	49.1	52.1	58.6	43.4	44.3	50	56.9
RN	45.9	55.7	52.3	53.4	45.8	56	52.1	53.5	45.8	53.5	51.8	54.8
SVMs	45.9	51.6	49.5	56.8	46.2	49.8	46.5	58.9	45.9	51.7	47.5	58.5

Tabla 4.3: Promedios % de las métricas para el conjunto S3, con parámetros por default.

Escala	R1				R2				R3			
% Información relevante	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %
<i>n</i> -PCs	1	4	8	12	1	5	8	11	1	4	7	12
<i>Accuracy</i>												
AD	72.2	72.2	71.5	69	72.2	71.3	70.8	67.9	72.2	72.2	70.2	67.1
<i>k</i> -nn	61.9	60.7	61.5	63.9	61.2	66.6	60.5	63.3	61.3	59.8	56	63.9
NB	72.4	70.8	72.7	70.5	72.2	71.3	72.9	70.7	72.3	71.1	73.4	69.4
RN	72.1	68.3	65.7	62.6	72.1	66.4	64.8	64.9	72.1	68.8	65.2	63.2
SVMs	72.2	72.2	72.2	72.2	72.2	72.2	60.5	72.2	72.2	72.2	72.2	72.2
<i>Precision</i>												
AD	52.1	52.1	56.7	58.7	52.1	60.3	58	58.5	52.1	52.1	57.5	60.2
<i>k</i> -nn	60.6	61.1	62.6	62.2	60.8	65.6	52.1	61.9	60.8	60.1	56.2	62
NB	60.6	51.8	68.6	64.7	52.1	65	69.1	65.2	54.9	52.4	70.1	62.9
RN	52.1	62.6	63.1	62.7	52.1	61.7	62.9	64.3	52.1	62.4	63	63.5
SVMs	52.1	52.1	52.1	52.1	52.1	52.1	52.1	52.1	52.1	52.1	52.1	52.1
<i>Recall</i>												
AD	72.2	72.2	71.5	69	72.2	71.3	70.8	67.9	72.2	72.2	70.2	67.1
<i>k</i> -nn	61.9	60.7	61.5	63.9	61.2	66.6	72.2	63.3	61.3	59.8	56	63.9
NB	72.4	70.8	72.7	70.5	72.2	71.3	72.9	70.7	72.3	71.1	73.4	69.4
RN	72.1	68.3	65.7	62.6	72.1	66.4	64.8	64.9	72.1	68.8	65.2	63.2
SVMs	72.2	72.2	72.2	72.2	72.2	72.2	72.2	72.2	72.2	72.2	72.2	72.2
<i>F-measure</i>												
AD	60.5	60.5	60.7	61.5	60.5	61.3	61	61.3	60.5	60.5	60.9	62.2
<i>k</i> -nn	61.1	60.9	62	63	61.2	66.6	60.5	63.3	61	60	56.1	62.8
NB	61	59.8	66.5	65.1	60.5	64.3	67.9	65.4	60.7	60.1	68.4	63.8
RN	60.5	63.9	64.1	62.7	60.4	63.2	63.6	64.5	60.5	63.8	63.8	63.3
SVMs	60.5	60.5	60.5	60.5	62.8	60.5	59.5	60.5	60.5	60.5	59.5	60.2

Tabla 4.4: Promedios % de las métricas para el conjunto $S1$, con parámetros modificados.

Escala	R1				R2				R3			
% Información relevante	53 %	80 %	85 %	90 %	53 %	80 %	85 %	90 %	53 %	80 %	85 %	90 %
n -PCs	1	5	7	10	1	4	7	10	1	4	6	10
<i>Accuracy</i>												
AD	49	47.1	53.6	53.3	49.3	47.1	47.6	50.7	48.3	47.9	55	51.9
k -nn	44.3	67.1	64.8	64.8	46.7	75	59.5	67.1	45.5	67.4	63.3	68.3
NB	55.5	56.4	59	54.8	54.5	55.7	49.3	52.9	55.5	51.7	58.3	57.6
RN	58.3	60.5	61.4	60.5	56.9	63.6	59.3	64.5	57.4	62.6	63.3	59.3
SVMs	53.1	65.2	68.8	67.4	53.8	66.4	57.8	65.7	53.8	65.3	70.5	65.5
<i>Precision</i>												
AD	49	46.6	53.6	53.7	49.3	46.8	47.5	50.7	48.1	47.5	55.2	52
k -nn	44.3	67.3	65.4	69.9	46.7	75.2	60.2	68.2	45.5	67.5	64.2	72
NB	56.5	56.7	60.5	57.1	55.4	56	49	54.3	56.7	51.8	59.6	59.9
RN	58.5	60.7	61.6	60.7	57.1	63.7	56.4	64.7	57.5	62.7	63.5	59.4
SVMs	53.4	65.7	69	67.4	54.2	66.8	57.9	65.8	54	65.5	70.7	65.6
<i>Recall</i>												
AD	49	47.1	53.6	53.3	49.3	47.1	47.6	50.7	48.3	47.9	55	51.9
k -nn	44.3	67.1	64.8	64.8	46.7	75	59.5	67.1	45.5	67.4	63.3	68.3
NB	55.5	56.4	59	54.8	54.5	55.7	49.3	52.9	55.5	51.7	58.3	57.6
RN	58.3	60.5	61.4	60.5	56.9	63.6	59.3	64.5	57.4	62.6	63.3	59.3
SVMs	53.1	65.2	68.8	67.4	53.8	66.4	57.8	65.7	53.8	65.3	70.5	65.5
<i>F-measure</i>												
AD	47.8	45.3	53.4	52.7	48.8	46.2	46.3	50.4	47.4	46.8	54.8	51.5
k -nn	44.2	67.1	64.4	62.3	46.6	75	58.9	66.7	45.4	67.3	62.8	67
NB	53.7	56	57.6	50.7	52.6	55.2	46.1	48.4	53.3	51	56.9	55
RN	58.1	60.2	61.3	60.3	56.7	63.5	59.1	64.4	57.1	62.5	63.2	59.2
SVMs	52.4	65	68.7	67.4	52.8	66.3	57.8	65.7	53.3	65.1	70.4	65.4

Tabla 4.5: Promedios % de las métricas para el conjunto S2, con parámetros modificados.

Escala	R1				R2				R3			
% Información relevante	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %
n -PCs	1	6	9	13	1	5	8	13	1	6	9	12
<i>Accuracy</i>												
AD	48.9	48.8	51.9	50.6	48.9	48.6	52.4	49.4	48.7	53.6	53.7	49.9
k -nn	51.8	60.3	60.7	61.5	54.7	59.6	65.9	59.9	53	61	64.7	60.5
NB	47.6	46.9	50.7	52	47.6	47.6	46.3	50.7	47.6	47.1	48.9	50.2
RN	48.9	58.3	54.7	56	49.2	56.9	55.9	54.5	48.6	59.8	55.8	55.4
SVMs	47.8	52.9	56.6	57.4	48	52.6	59.5	57.5	46.6	57.5	58.8	58.6
<i>Precision</i>												
AD	48.9	48.7	56.9	50.9	48.8	48.6	57.2	48.9	48.4	61.2	62.3	49.5
k -nn	51.8	60.7	60.7	61.8	54.7	60	66.2	60	53	61.1	65.1	60.6
NB	46.5	46.9	50.7	52.1	46.5	46.5	46.1	50.8	46.5	46.9	48.9	50.2
RN	48.9	58.6	54.7	56	49.1	57.1	55.9	54.6	48.5	59.9	55.9	55.4
SVMs	47.8	53.1	56.6	57.5	47.8	53	59.5	57.6	46.5	58.2	58.8	58.6
<i>Recall</i>												
AD	48.9	48.8	51.9	50.6	48.9	48.6	52.4	49.4	48.7	53.6	53.7	49.9
k -nn	51.8	60.3	60.7	61.5	54.7	59.6	65.9	59.9	53	61	64.7	60.5
NB	47.6	46.9	50.7	52	47.6	47.6	46.3	50.7	47.6	47.1	48.9	50.2
RN	48.9	58.3	54.7	56	49.2	56.9	55.9	54.5	48.6	59.8	55.8	55.4
SVMs	47.8	52.9	56.6	57.4	48	52.6	59.5	57.5	46.6	57.5	58.8	58.6
<i>F-measure</i>												
AD	48.5	48	44.7	47.1	47.2	48.1	44.6	43	46.3	45.8	44.8	45.1
k -nn	51.7	60.1	60.7	61.4	54.6	59.4	65.7	59.7	52.9	60.8	64.4	60.3
NB	43	46.8	50.7	51.1	43	43	45.5	49.8	43	45.8	48	49.3
RN	47.4	58	54.4	55.8	48.1	56.7	55.6	54.4	47.8	59.6	55.8	55.2
SVMs	46.9	52.1	56.5	57.3	47	51.8	59.5	57.4	45.9	56.6	58.8	58.5

Tabla 4.6: Promedios % de las métricas para el conjunto S3, con parámetros modificados.

Escala	R1				R2				R3			
% Información relevante	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %	57 %	80 %	85 %	90 %
n -PCs	1	4	8	12	1	5	8	11	1	4	7	12
<i>Accuracy</i>												
AD	72.2	72.2	71.3	71.1	72.2	72	72.1	70.9	72.2	72.2	70.2	70.9
k -nn	63.7	69	72.1	68.7	64.7	75.2	70.8	67.7	63.7	69.9	71.1	67.4
NB	72.8	71.1	72.1	71.6	72.8	71.3	72.8	72.6	72.8	72.2	73	71.7
RN	72.2	70.167.8	66	72	69.4	68.5	70.5	72.2	70.3	68.6	66.4	
SVMs	72.2	72.2	71.9	71.6	72.2	72.2	73.8	73.2	72.2	72.2	74.8	72.2
<i>Precision</i>												
AD	52.1	52.1	59.5	57.6	52.1	52.1	52.1	52.8	52.1	52.1	57.6	55.1
k -nn	55.9	62.9	68.4	62.3	57.7	72.9	65.7	59	56.5	64.1	65.8	57.8
NB	80.3	60.6	67.1	66.1	80.3	64.4	68.9	68.5	80.3	52.1	67.9	52
RN	52.1	59.6	61.7	63.5	52.1	63	64.1	65.6	52.1	57.3	63.4	63.3
SVMs	52.1	52.1	61.4	68.4	52.1	52.1	70.8	70.9	52.1	52.1	72.8	52.1
<i>Recall</i>												
AD	72.2	72.2	71.3	71.1	72.2	72	72.1	70.9	72.2	72.2	70.2	70.9
k -nn	63.7	69	72.1	68.7	64.7	75.2	70.8	67.7	63.7	69.9	71.1	67.4
NB	72.8	71.1	72.1	71.6	72.8	71.3	72.8	72.6	72.8	72.2	73	71.7
RN	72.2	70.1	67.8	66	72	69.4	68.5	70.5	72.2	70.3	68.6	66.4
SVMs	72.2	72.2	71.9	71.6	72.2	72.2	73.8	73.2	72.2	72.2	74.8	72.2
<i>F-measure</i>												
AD	60.5	60.5	61.5	61	60.5	60.4	60.4	60	60.5	60.5	60.9	60.3
k -nn	58.8	64.2	68.3	63.7	60.2	72.1	65.8	61.3	59.2	64.9	65.8	60.6
NB	62.1	61.1	65.1	65.2	62.1	63.8	65.9	66.1	62.1	60.5	65.5	60.3
RN	60.5	61.5	63.3	64.5	60.4	63.8	65.1	65.9	60.5	61.1	64.4	64.5
SVMs	60.5	60.5	61.9	69.1	60.5	60.5	69	71.1	60.5	60.5	70.2	60.5

Resultados de la clasificación con imágenes con procesamiento

Las Tablas: 4.7, 4.8, 4.9 y 4.10 presentan los resultados de la clasificación con el conjunto $S2$ que consta de 84 imágenes para las diferentes técnicas de procesamiento con los parámetros por default. Para la técnica *Canny* el mejor resultado fue obtenido con el algoritmo naive Bayes con 61,1 % de *precision* usando 50 componentes principales que representan el 80 % de información con un tamaño de resolución de 979×979 ; *range filter* obtuvo 67,7 % de *precision* con naive Bayes y tamaño de resolución de 1958×1958 usando 37 componentes principales que representan el 90 % de información; *k*-vecinos más cercanos obtuvo el mejor resultado para la técnica ecualización del histograma con 64,7 % con un tamaño de resolución de 490×490 usando 24 componentes principales que representan el 90 % de información y para la técnica de binarización donde obtuvo 62,3 % para las métricas de *accuracy*, *precision* y *recall* con un tamaño de resolución de 490×490 usando 16 componentes principales que representan el 80 % de información.

Los resultados de la clasificación con los parámetros modificados para las diferentes técnicas de procesamiento del conjunto $S2$ se muestran en las Tablas 4.15, 4.16, 4.17 y 4.18. La técnica *Canny* con el algoritmo naive Bayes obtuvo el mejor resultado de 70,8 % de *precision* con un tamaño de resolución de 979×979 usando 55 componentes principales que representan el 85 % de información, los parámetros modificados fueron: *useKernelEstimator* = *false* y *useSupervisedDiscretization* = *true*; el algoritmo *SVMs* obtuvo 68,5 % de *precision* como mejor resultado, usando 14 componentes principales que representan el 80 % de información, con un tamaño de resolución de 1958×1958 para *range filter*, los parámetros modificados fueron: $c = 1,5$, *kernel* = *PolyKernel-E* 2,0, *numFolds* = 3 y *randomSeed* = aleatorio; la técnica ecualización del histograma obtuvo el mejor resultado de 64,5 % de *precision* con *k*-nn y tamaño de resolución de

490 × 490 usando 24 componentes principales que representan el 90 % de información, los parámetros que se modificaron fueron: $KNN = 1$, *nearestNeighbourSearchAlgorithm = BallTree* y *distanceFunction = EuclideanDistance*; el algoritmo anterior con el mismo tamaño de resolución y parámetros obtuvieron 62,1 % en todas las métricas usando 16 componentes principales que representan el 80 % de información para la técnica de binarización.

Para el conjunto *S3* de 151 imágenes los resultados obtenidos de la clasificación se muestran en las Tablas 4.11, 4.12, 4.13 y 4.14, cuyos experimentos fueron realizados con los parámetros por default, los mejores resultados se detallan de acuerdo al tipo de procesamiento de imágenes. *Canny* con 73,3 % como mejor resultado, usando 108 componentes principales, mientras que ecualización del histograma obtuvo el mejor resultado de 73,5 usando 30 componentes principales que representan el 90 % de información, ambas técnicas con un tamaño resolución de 490 × 490; *range filter* obtuvo 72,2 % con un tamaño de resolución de 979 × 979 usando 15 componentes principales que representan el 80 % de información y la técnica de binarización logró el 72,2 % para los tres tamaños de resolución usando 20, 22, 26 componentes principales respectivamente que representan el 80 % de información, todas las técnicas obtuvieron los mejores resultados con el algoritmo *SVMs* con la métricas *accuracy recall*.

Los resultados de la clasificación con los parámetros modificados del conjunto *S3* de las diferentes técnicas de procesamiento se muestran en las Tablas: 4.19, 4.20, 4.21 y 4.22.

El mejor resultado para *Canny* fue obtenido con *k-nn* de 73,9 % de *accuracy* y *recall*, usando 80 componentes principales que representan el 80 % de información y

tamaño de resolución de 979×979 , los parámetros modificados fueron: $KNN= 5$, $nearestNeighbourSearchAlgorithm=LinearNNSearch$ y $distanceFunction=ManhattanDistance$.

La técnica *range filter* obtuvo los mejores resultados con naive Bayes 72,2% de *accuracy* y *recall* usando 25 y 35 componentes para el tamaño de resolución 490×490 y para la resolución 979×979 , 15 y 28 componentes, ambas resoluciones representando el 80% y 85% de información respectivamente y para el tamaño de resolución 1958×1958 con 78 componentes principales que representan el 80% de información y el algoritmo *SVMs* obtuvo el mismo resultado para las mismas métricas que el algoritmo anterior para todas las resoluciones, con el 80%, 85% y 90%, usando entre 15 y 58 componentes principales, los parámetros modificados de naive Bayes para cada resolución fueron los siguientes: $useKernelEstimator = false$ y $useSupervisedDiscretization = true$ y para *SVMs* fueron: $c = 1,5$, $kernel = RBFKernel-G 0,02$, $numFolds = -1$ y $randomSeed =$ aleatorio.

La técnica ecualización del histograma obtuvo el mismo porcentaje para las mismas métricas de la técnica anterior, los algoritmos que mejor se desempeñaron son los siguientes: naive Bayes usó entre 12 y 30 componentes para representar del 80% al 90% de información con un tamaño de resolución de 490×490 , para el tamaño de resolución 979×979 se usaron 13 componentes principales que representan el 80% de información y para el tamaño de resolución 1958×1958 se usaron entre 13 y 32 componentes principales que representan el 80% y 85% respectivamente y el algoritmo *SVMs* usó entre 12 y 32 componentes principales que representan del 80% al 90% de información para los tres tamaños de resolución, los parámetros modificados para cada algoritmo fueron los siguientes: naive Bayes con $useKernelEstimator = false$ y $useSupervisedDiscretization = true$; *SVMs* $c = 1,5$, $kernel = RBFKernel-G 0,02$, $numFolds$

Tabla 4.7: Promedios % de las métricas para *Canny* del conjunto *S2*, con parámetros por default.

Escala	R1			R2			R3		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	54	59	64	50	55	60	47	52	57
<i>Accuracy</i>									
<i>k</i> -nn	52.2	57.3	55.1	56.1	53	53	47.6	44.8	49.6
NB	58.9	58.8	60.6	60.1	59.3	58	49.3	49.9	51.8
RN	52.6	48.1	50.7	55.4	50.1	53.6	49.6	51	49
SVMs	58.9	60.2	54.3	55.8	52.8	57.4	46.3	47.3	48.2
<i>Precision</i>									
<i>k</i> -nn	52.6	57.5	55.3	56.1	53	53	47.6	43.5	49.6
NB	59	58.9	60.6	61.1	59.6	58.2	49.3	49.9	51.9
RN	52.8	47.9	50.7	55.4	50.1	53.6	49.6	51	49
SVMs	59.3	60.3	54.4	56.3	52.9	57.5	46.3	47.2	48.2
<i>Recall</i>									
<i>k</i> -nn	52.5	57.3	55.1	56.1	53	53	47.6	44.8	49.6
NB	58.9	58.8	60.6	60.1	59.3	58	49.3	49.9	51.8
RN	52.6	48.1	50.7	55.4	50.1	53.6	49.6	51	49
SVMs	58.9	60.2	54.3	55.8	52.8	57.4	46.3	47.3	48.2
<i>F-measure</i>									
<i>k</i> -nn	52.6	56.9	54.8	56	52.9	52.9	47.6	42	46.7
NB	58.8	58.7	60.5	59.3	59.1	57.8	48.3	48.8	51.2
RN	52	47	50.3	55.2	50.1	53.5	46.2	41.7	48
SVMs	58.5	60.2	54.1	55.2	52.3	57.2	48.3	48.8	51.2

= -1 y *randomSeed*=aleatorio. Y la técnica de binarización obtuvo los mejores resultados con los mismos algoritmos, métricas y conjuntos que la técnica anterior, así como los mismos parámetros modificados, usando entre 20 y 55 componentes principales que representan del 80 % al 90 %.

Comparación de los mejores algoritmos con la métrica *F-measure*

El desempeño de los mejores algoritmos se muestra en la Figura 4.6, donde se representa el promedio % de *F-measure* para cada conjunto. En la gráfica 4.6 a) los conjuntos

Tabla 4.8: Promedios % de las métricas para *range-filter* del conjunto *S2*, con parámetros por default.

Escala	<i>R1</i>			<i>R2</i>			<i>R3</i>		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	17	24	34	11	18	29	14	23	37
<i>Accuracy</i>									
<i>k</i> -nn	55.3	59.3	52.9	59.7	56.4	58.9	65.6	60.7	58.3
NB	52.4	47.6	51.7	54	59.3	59	62.6	62	66.7
RN	62.4	57.3	54.8	58.5	58.3	61.3	60.3	60.7	61.7
SVMs	52.8	60.4	54.6	53	67.4	61.1	65	66.3	57
<i>Precision</i>									
<i>k</i> -nn	55.3	59.4	52.9	60	56.6	59	65.6	60.7	58.4
NB	52.7	47.6	51.7	55	59.8	59.1	64	63.1	67.7
RN	62.4	57.3	54.8	58.5	58.4	61.4	60.3	60.8	61.8
SVMs	52.9	60.7	55	53	67.5	61.2	65.4	67.3	57.3
<i>Recall</i>									
<i>k</i> -nn	55.3	59.3	52.9	59.7	56.4	58.9	65.6	60.7	58.3
NB	52.4	47.6	51.7	54	59.3	59	62.6	62	66.7
RN	62.4	57.3	54.8	58.5	58.3	61.3	60.3	60.7	61.7
SVMs	52.8	60.4	54.6	53	67.4	61.1	65	66.3	57
<i>F-measure</i>									
<i>k</i> -nn	55	59.1	52.8	59.5	56.2	58.9	65.6	60.7	58.2
NB	50.7	47.5	51.1	51.3	58.7	59	61.7	61.2	66.2
RN	62.3	57.1	54.7	58.4	58.3	61.2	60.2	60.7	61.6
SVMs	52.1	60.1	53.6	52.8	67.4	61	64.8	65.9	56.6

Tabla 4.9: Promedios% de las métricas para *ecualización del histograma* del conjunto *S2*, con parámetros por default.

Escala	<i>R1</i>			<i>R2</i>			<i>R3</i>		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	12	16	24	12	17	25	12	17	25
<i>Accuracy</i>									
<i>k</i> -nn	55.3	63.9	64.2	52	58.7	60.8	53.2	59.6	60.8
NB	45.6	43.1	47	43.6	40.1	49.9	44.6	40.8	52.3
RN	50	49.8	52.6	49.6	50.5	56.4	51.9	51.8	59.3
SVMs	54.3	56.1	50.8	53.8	54.6	59.8	53.4	53.7	58.7
<i>Precision</i>									
<i>k</i> -nn	55.3	64	64.7	53	58.7	61.1	53.2	59.7	61.1
NB	45.5	43	46.8	43.5	40.1	49.9	44.6	40.8	52.6
RN	50	49.8	52.6	49.6	50.5	56.5	51.9	51.8	59.3
SVMs	54	56.5	50.8	54.2	54.9	59.9	53.6	54.1	58.7
<i>Recall</i>									
<i>k</i> -nn	55.3	63.9	64.2	53	58.7	60.8	53.2	59.6	60.8
NB	45.6	43.1	47	43.6	40.1	49.9	44.6	40.8	52.3
RN	50	49.8	52.6	49.6	50.5	56.4	51.9	51.8	59.3
SVMs	54.3	56.1	50.8	53.8	54.6	59.8	53.4	53.7	58.7
<i>F-measure</i>									
<i>k</i> -nn	55.1	63.9	63.9	52.9	58.6	60.6	53.2	59.6	60.7
NB	45.4	43	46	43.4	40.1	49	44.5	40.8	51.1
RN	48.9	49.6	52.6	49.5	50.4	56.4	51.7	51.7	59.3
SVMs	53.2	55.3	50.7	52.5	53.9	59.7	52.2	52.8	58.6

Tabla 4.10: Promedios % de las métricas para binarización del conjunto S2, con parámetros por default.

Escala	R1			R2			R3		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
n -PCs	16	23	33	17	24	34	20	27	37
<i>Accuracy</i>									
k -nn	62.3	53.7	51.2	60.9	57.1	52.8	57	57.1	54.3
NB	41.8	44.8	43.7	42.9	46.2	42.1	42.4	42.5	41.2
RN	51.7	48.7	47.7	51.7	50.4	48.8	47.6	46.4	49.2
SVMs	44.9	47.3	47.7	43.2	48.7	47	47.4	46.8	47
<i>Precision</i>									
k -nn	62.3	53.7	51.2	61	57.2	52.8	57	57.1	54.3
NB	41.6	44.7	43.5	42.6	46.2	41.9	42.1	42.2	41.1
RN	51.7	48.7	47.7	51.7	50.4	48.8	47.6	46.4	49.2
SVMs	44.8	47.2	47.7	43.1	48.7	47	47.4	46.7	47
<i>Recall</i>									
k -nn	62.3	53.7	51.2	60.9	57.1	52.8	57	57.1	54.3
NB	41.8	44.8	43.7	42.9	46.2	42.1	42.4	42.5	41.2
RN	51.7	48.7	47.7	51.7	50.4	48.8	47.6	46.4	49.2
SVMs	44.9	47.3	47.7	43.2	48.7	47	47.4	46.8	47
<i>F-measure</i>									
k -nn	62.2	53.6	51.2	60.9	57.1	52.7	57	57.1	54.2
NB	41.5	44.6	43.4	42.3	46	41.8	41.9	42	41.1
RN	51.5	48.7	47.7	51.5	50.3	48.8	47.6	46.3	49.1
SVMs	44.6	47	47.7	43	48.4	46.9	47.3	46.6	46.9

Tabla 4.11: Promedios % de las métricas para *Canny* del conjunto *S3*, con parámetros por default.

Escala	<i>R1</i>			<i>R2</i>			<i>R3</i>		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	90	98	108	80	89	100	78	85	97
<i>Accuracy</i>									
<i>k</i> -nn	59.2	56	63.2	69.1	64.4	61.6	67.9	64	59
NB	49	48.5	52.6	47.9	50.8	52.9	38.5	44.4	47.6
RN	61.9	62.4	58.5	69.2	66.6	65.8	69	68.8	69.3
SVMs	71.7	73.2	73.3	72.9	72.7	72.4	70.8	70.7	70.9
<i>Precision</i>									
<i>k</i> -nn	63.2	61.8	66.6	68.2	65.3	64.2	64.7	64.2	62.2
NB	60.7	58.5	60.2	60.6	62.1	62	54.6	58	59.3
RN	62.7	63.9	61.9	67	64.4	64.5	65.4	65.6	65.5
SVMs	66.5	69.6	69.9	69.2	68.8	67.8	61.4	62.8	62.8
<i>Recall</i>									
<i>k</i> -nn	59.2	56	63.2	69.1	64.4	61.6	67.9	64	59
NB	49	48.5	52.6	47.9	50.8	52.9	38.5	44.4	47.6
RN	61.9	62.4	58.5	69.2	66.6	65.8	69	68.8	69.3
SVMs	71.7	73.2	73.3	72.9	72.7	72.4	70.8	70.7	70.9
<i>F-measure</i>									
<i>k</i> -nn	60.7	58	64.4	68.6	64.8	62.7	65.7	64.1	60.3
NB	51.5	51.2	55	50.3	53.2	55.3	39.7	46.7	50.1
RN	62.3	63	59.7	67.7	65.2	65	66.4	66.5	66.2
SVMs	65.9	67.4	67.7	65.4	65.5	65.3	62	62.4	62.6

Tabla 4.12: Promedios % de las métricas para *range-filter* del conjunto *S3*, con parámetros por default

Escala	<i>R1</i>			<i>R2</i>			<i>R3</i>		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	25	35	54	15	28	44	20	38	58
<i>Accuracy</i>									
<i>k</i> -nn	65	63.2	64.5	63	63.2	62.9	66.4	69.4	70
NB	55	54.7	61.4	58.9	52.4	53.7	58.3	52.5	52.8
RN	63.8	59.1	62.5	59.2	60.7	64.6	63.2	64.6	64.5
SVMs	71.9	71.5	71.4	72.2	71.1	71	71.6	69.9	71.8
<i>Precision</i>									
<i>k</i> -nn	63.3	62.4	63.1	60.8	62	63.3	66.7	67.9	68
NB	62.6	66.3	70	59.1	63.9	63.7	59.7	60.6	59.1
RN	62.2	60.2	63.9	56.4	60.9	64.8	63.1	64.2	63.8
SVMs	52.1	52	64.2	52.1	51.9	55.3	52	59	66.5
<i>Recall</i>									
<i>k</i> -nn	65	63.2	64.5	63	63.2	62.9	66.4	69.4	70
NB	55	54.7	61.4	58.9	52.4	53.7	58.3	52.5	52.8
RN	63.8	59.1	62.5	59.2	60.7	64.6	63.2	64.6	64.5
SVMs	71.9	71.5	71.4	72.2	71.1	71	71.6	69.9	71.8
<i>F-measure</i>									
<i>k</i> -nn	64	62.8	63.7	61.8	62.5	62.5	66.5	68.4	68.7
NB	57.3	56.9	63.4	59	54.7	56.1	58.9	54.9	55
RN	62.9	59.6	63.1	57.6	60.8	64.7	63.1	64.4	64.1
SVMs	60.4	60.2	62.8	60.5	60	60.4	60.2	61.2	65.6

Tabla 4.13: Promedios% de las métricas para *ecualización del histograma* del conjunto *S3*, con parámetros por default.

Escala	R1			R2			R3		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	12	19	30	13	20	32	13	20	32
<i>Accuracy</i>									
<i>k</i> -nn	65	65.8	65.4	65.1	66	62.9	65.6	67.3	65.8
NB	65.4	64.3	66.6	64.4	61	53.6	65.2	63.7	67.2
RN	64.6	62.9	63.2	66.2	62.5	66.1	66.7	64.6	65.8
SVMs	72.2	72.2	73.5	72.2	72.2	71.3	72.2	72.2	72.8
<i>Precision</i>									
<i>k</i> -nn	62.3	63.8	63.4	62.5	63	62.3	63.1	64.4	63.3
NB	55.6	56	60.7	53.9	51.7	63.3	55.4	54.9	61.7
RN	64	62.2	63.3	64.7	61.7	65.6	64.3	63.4	66
SVMs	52.1	52.1	73	52.1	52.1	57.1	52.1	52.1	69.6
<i>Recall</i>									
<i>k</i> -nn	65	65.8	65.4	65.1	66	62.9	65.6	67.3	65.8
NB	65.4	64.3	66.6	64.4	61	53.6	65.2	63.7	67.2
RN	64.6	62.9	63.2	66.2	62.5	66.1	65.7	64.6	65.8
SVMs	72.2	72.2	73.5	72.2	72.2	71.3	72.2	72.2	72.8
<i>F-measure</i>									
<i>k</i> -nn	63.4	64.7	64.2	63.5	64.1	62.5	64.2	65.5	64.3
NB	59.1	59	62.4	58	55.7	56	58.9	58.2	63.3
RN	64.2	62.5	63.2	65.3	62	65.8	64.9	63.9	65.9
SVMs	60.5	60.5	64.6	60.5	60.5	61	60.5	60.5	63.8

Tabla 4.14: Promedios % de las métricas para binarización del conjunto S3, con parámetros por default.

Escala	R1			R2			R3		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
n -PCs	12	19	30	13	20	32	13	20	32
<i>Accuracy</i>									
k -nn	64.5	66	62.3	64.9	65.6	62.5	65.4	62.7	65
NB	63.1	57.9	55.4	62.3	55.6	54.5	57.9	51.9	58.2
RN	59.1	63.2	60.3	59	64.6	58.5	60.1	65.9	67.5
SVMs	61.7	71.1	69.2	72.2	70.7	69.1	72.2	71.1	69.5
<i>Precision</i>									
k -nn	64.5	66.6	62.2	64.5	66.8	62.8	66.7	64.4	64.9
NB	55.9	52.6	51.7	55.2	52.9	52.1	52.2	50.7	57.3
RN	60	62.8	61.6	59.2	64.7	59.8	60.6	65.3	67.7
SVMs	52.1	51.9	61.8	52.1	54.2	61.9	52.1	57.3	64.5
<i>Recall</i>									
k -nn	64.5	66	62.3	64.9	65.6	62.5	65.4	62.7	65
NB	63.1	57.9	55.4	62.3	55.6	54.5	57.9	51.9	58.2
RN	59.1	63.2	60.3	59	64.6	58.5	60.1	65.9	67.5
SVMs	72.2	71.1	69.2	72.2	70.7	69.1	72.2	71.1	69.5
<i>F-measure</i>									
k -nn	64.5	66.3	62.2	64.7	66.1	62.7	66	63.4	64.9
NB	58.5	54.9	53.4	58	54.1	53.2	54.8	51.3	57.7
RN	59.5	62.9	60.9	59	64.6	59.1	60.3	65.5	67.6
SVMs	60.5	60	63	60.5	60	63.1	60.5	60.6	65.5

Tabla 4.15: Promedios % de las métricas para *Canny* del conjunto *S2*, con parámetros modificados.

Escala	<i>R1</i>			<i>R2</i>			<i>R3</i>		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	54	59	64	50	55	60	47	52	57
<i>Accuracy</i>									
<i>k</i> -nn	60.8	56.7	56.7	62.3	64.4	63.9	61.3	56.2	56.1
NB	58.3	58.7	57.3	66.8	67.5	67.7	47.8	49.4	50
RN	54.8	50.8	48.8	55.5	52.5	53	53.8	53.1	50.8
SVMs	59.5	55.4	53.48	56.8	54.2	53.5	56.5	58.1	57.3
<i>Precision</i>									
<i>k</i> -nn	61	56.9	56.9	62.3	64.4	64.4	61.4	56.3	56.3
NB	58.4	58.9	57.3	69.7	70.8	70.2	47	49.4	50
RN	55	50.8	48.8	55.5	52.5	53	53.8	53.1	50.9
SVMs	59.5	55.8	54.4	56.8	54.2	53.5	53.5	58.2	57.8
<i>Recall</i>									
<i>k</i> -nn	60.8	56.7	56.7	62.3	64.4	63.9	61.3	56.2	56.1
NB	58.3	58.7	57.3	66.8	67.5	67.4	47.8	49.4	50
RN	54.8	50.8	48.8	55.5	52.5	53	53.8	53.1	50.8
SVMs	59.5	55.4	53.8	56.8	54.2	53.5	56.5	58.1	57.3
<i>F-measure</i>									
<i>k</i> -nn	60.7	56.2	56.2	62.2	64.4	63.6	60.8	55.9	55.7
NB	58.2	58.5	57.2	65.5	66.2	66.1	44.3	48.1	49
RN	54.2	50.3	48.4	55.4	52.4	52.9	53.7	52.8	50.7
SVMs	59.5	54.5	52.7	56.7	54.1	53.4	56.3	57.9	56.5

Tabla 4.16: Promedios% de las métricas para *range-filter* del conjunto *S2*, con parámetros modificados.

Escala	<i>R1</i>			<i>R2</i>			<i>R3</i>		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
<i>n</i> -PCs	17	24	34	11	18	29	14	23	37
<i>Accuracy</i>									
<i>k</i> -nn	63.6	63.6	58.3	59.6	58.8	65.1	66.3	64.3	66.6
NB	56.7	48.7	57.1	53	56	57.4	61.9	62.7	67
RN	62.6	59.5	27.3	59.4	62	61.9	64.4	61.7	62
SVMs	59.9	58.8	64.3	59.1	60.6	62.4	68.4	65.5	62.5
<i>Precision</i>									
<i>k</i> -nn	63.8	64.1	58.5	59.8	59.2	65.2	66.3	64.3	66.9
NB	58.9	48.6	57.9	55.4	57.1	57.6	65.5	64.5	67.3
RN	62.7	59.6	57.3	59.5	62.1	61.9	64.4	61.8	62.1
SVMs	59.9	58.9	64.3	59.2	60.8	62.5	68.5	65.9	62.6
<i>Recall</i>									
<i>k</i> -nn	63.6	63.6	58.3	59.6	58.8	65.1	66.3	64.3	66.6
NB	56.7	48.7	57.1	53	56	57.4	61.9	62.7	67
RN	62.6	59.5	57.3	59.4	62	61.9	64.4	61.7	62
SVMs	59.9	58.8	64.3	59.1	60.6	62.4	68.4	65.5	62.5
<i>F-measure</i>									
<i>k</i> -nn	63.4	63.2	58.1	59.5	58.3	65.1	66.3	64.3	66.4
NB	53.8	48	56.1	47.2	54	57.1	59.6	61.6	66.9
RN	62.6	59.5	57.2	59.3	62	61.9	64.4	61.6	62
SVMs	59.9	58.8	64.3	58.9	60.5	62.3	68.4	65.3	62.5

Tabla 4.17: Promedios % de las métricas para ecalización del histograma del conjunto S_2 , con parámetros modificados.

Escala	$R1$			$R2$			$R3$		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
n -PCs	12	16	24	12	17	25	12	17	25
<i>Accuracy</i>									
k -nn	60.5	62.9	64.1	59.5	62	62.1	59.4	61	61.9
NB	47.6	47.6	53.1	47.6	47.6	52.8	47.6	47.6	49.5
RN	52.4	54.1	56.7	55.5	51	58.3	54.8	51.1	61.3
SVMs	61.1	58.5	54.6	60.6	58.5	58	61.1	57.1	62.4
<i>Precision</i>									
k -nn	60.5	62.9	64.5	59.5	62.1	62.4	59.5	61	62.1
NB	46.5	46.5	53.9	46.5	46.5	53.4	46.5	46.5	49.4
RN	52.4	54.1	56.7	55.6	51	58.4	54.9	51.1	61.4
SVMs	61.4	58.5	54.7	60.9	58.5	58	61.4	57.2	62.5
<i>Recall</i>									
k -nn	60.5	62.9	64.1	59.5	62	62.1	59.4	61	61.9
NB	47.6	47.6	53.1	47.6	47.6	52.8	47.6	47.6	49.5
RN	52.4	54.1	56.7	55.5	51	58.3	54.8	51.1	61.3
SVMs	61.1	58.5	54.6	60.6	58.5	58	61.1	57.1	62.4
<i>F-measure</i>									
k -nn	60.4	62.8	63.8	59.5	62	62	59.4	60.9	61.8
NB	43	43	50.5	43	43	50.4	43	43	46.7
RN	52.2	53.9	56.7	55.3	50.9	58.3	54.6	51	61.3
SVMs	60.8	58.4	54.5	60.3	58.4	58	60.8	57.1	62.3

Tabla 4.18: Promedios % de las métricas para binarización del conjunto $S2$, con parámetros modificados.

Escala	$R1$			$R2$			$R3$		
% Información relevante	80 %	85 %	90 %	80 %	85 %	90 %	80 %	85 %	90 %
n -PCs	16	23	33	17	24	34	20	27	37
<i>Accuracy</i>									
k -nn	62.1	54	55.4	60	56.9	55.5	56.8	56.7	57.5
NB	49.5	47.4	49.6	50.2	48.6	49	48.3	50.7	49.4
RN	50.5	48.8	47.9	52.7	50.7	49.3	50.1	47.6	47.9
SVMs	50.2	48.4	51.6	52.4	48.3	48.9	50	48.1	47.6
<i>Precision</i>									
k -nn	62.1	54	55.5	60	56.9	55.6	56.8	56.7	57.5
NB	49.4	47.1	49.6	50.2	48.4	48.8	42.7	50.8	49.4
RN	50.5	48.8	47.9	52.8	50.7	49.3	50.1	47.6	47.9
SVMs	50.2	48.4	51.6	52.4	48.2	48.9	50	48.1	47.6
<i>Recall</i>									
k -nn	62.1	54	55.4	60	56.9	55.5	56.8	56.7	57.5
NB	49.5	47.4	49.6	50.2	48.6	49	48.3	50.7	49.4
RN	50.5	48.8	47.9	52.7	50.7	49.3	50.1	47.6	47.9
SVMs	50.2	48.4	51.6	52.4	48.3	48.9	50	48.1	47.6
<i>F-measure</i>									
k -nn	62.1	53.9	55	60	56.9	55.3	56.8	56.6	57.5
NB	47.7	46.2	48.8	47.9	47.1	47.8	38.3	48.8	48.5
RN	50.3	48.7	47.8	52.6	50.6	49.3	50	47.5	47.8
SVMs	50.2	48.4	51.5	52.4	47.7	48.9	50	48.1	47.1

que obtuvieron mejores resultados fueron *S1* y *S3* con los parámetros modificados, en todos los subconjuntos *R1*, *R2*, *R3*, con porcentajes entre 68,7% y 75% con los algoritmos *k*-nn y *SVMs*, mientras que para la gráfica 4.6 b) los mejores resultados fueron de los conjuntos *range filter* con parámetros por default para *R2* y *R3*; *Canny* con *R2* y *range filter* con los tres tamaños de resolución ambos conjuntos con parámetros modificados, reportando porcentajes entre 64,3% y 67,4% con los algoritmos *SVMs*, naive Bayes y *k*-vecinos más cercanos. Y en la gráfica 4.6 c) los conjuntos que obtuvieron mejores resultados con parámetros por default: *Canny* con *R1* y *R2*, *range filter* con *R3*, binarización con *R3*; para los resultados con parámetros modificados *Canny* con los 3 tamaños de resolución, *range filter* con *R3*, ecualización del histograma con *R1* y binarización con *R3*, obteniendo porcentajes entre 67,6% y 71,6% con los algoritmos *SVMs*, *k*-nn y redes neuronales.

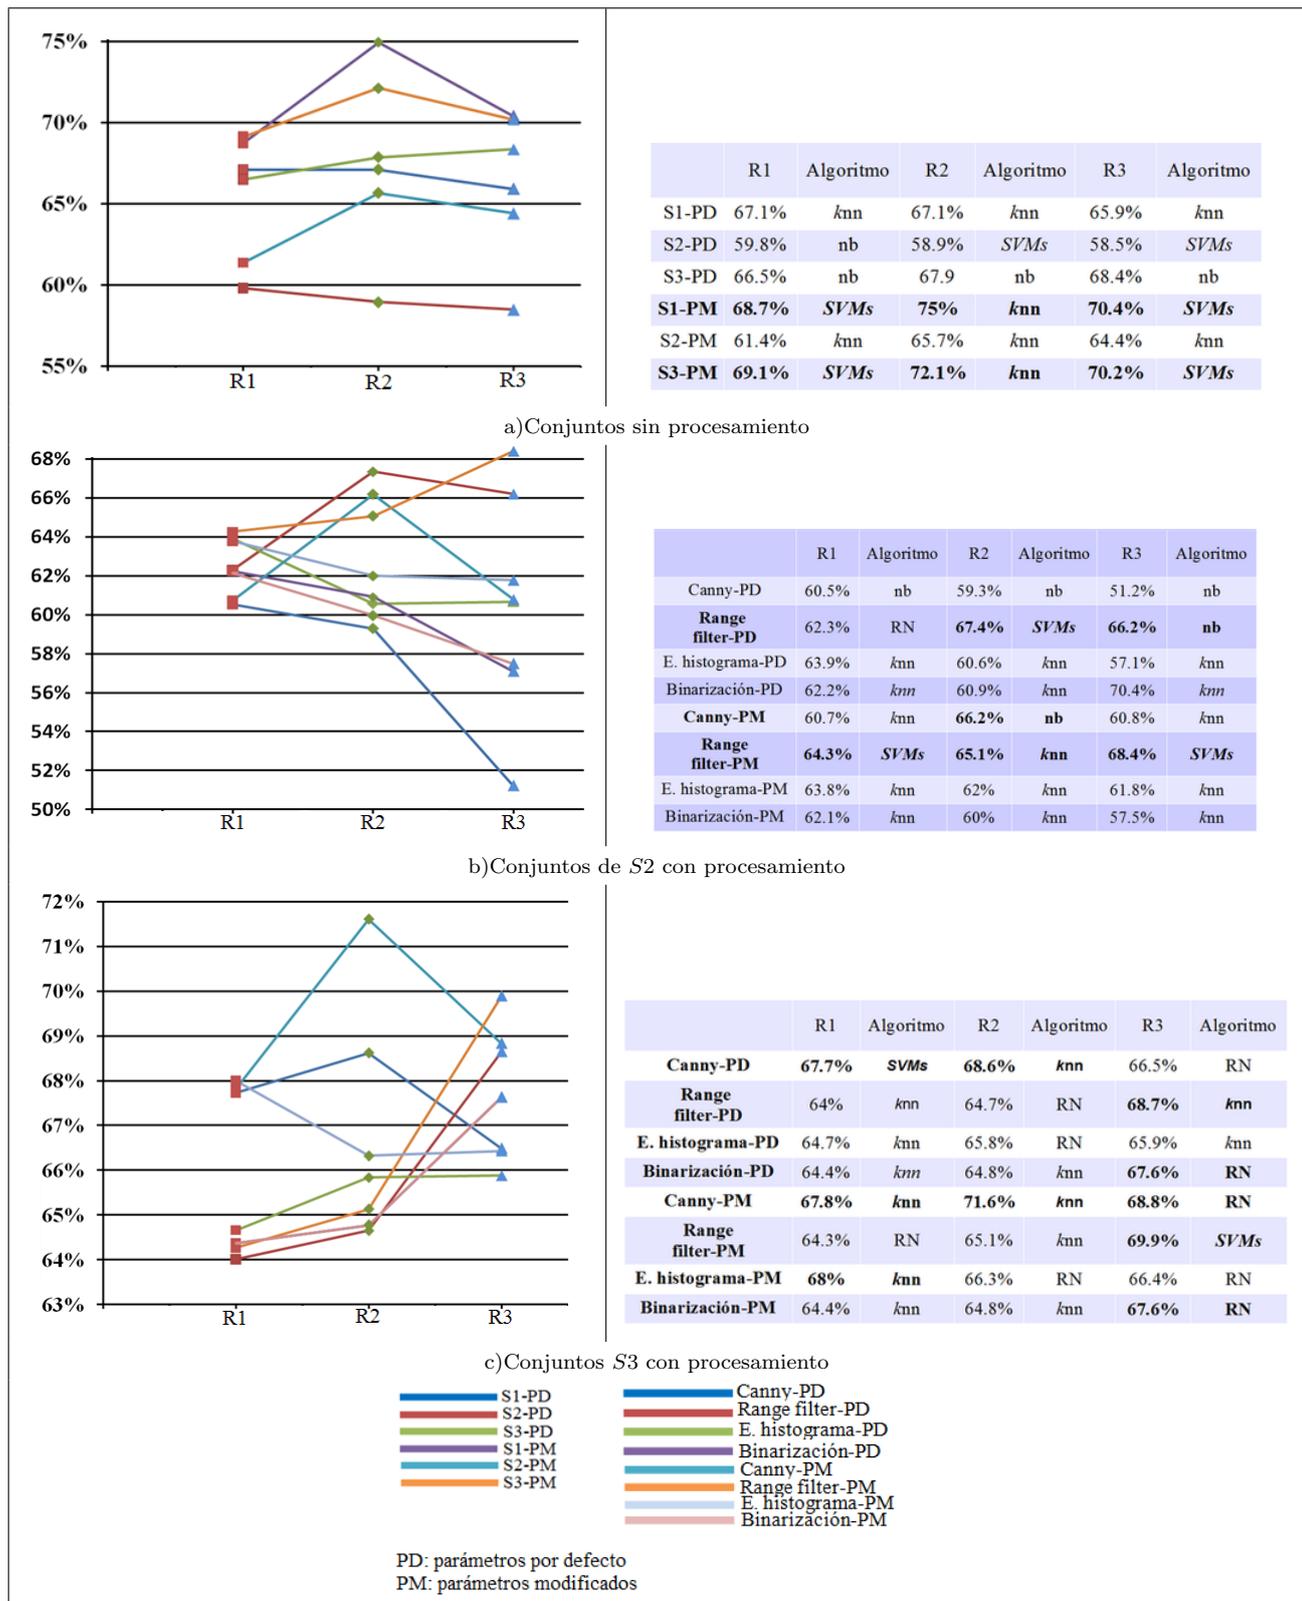


Figura 4.6: Promedio de la métrica *F-measure*.

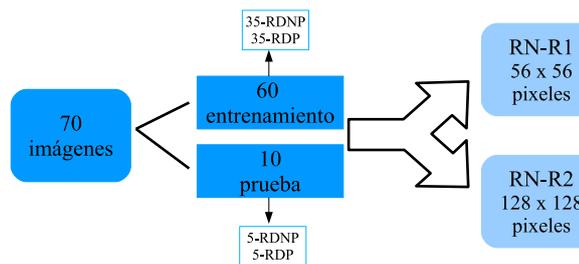


Figura 4.7: Conjuntos para la red neuronal de Hinton

4.4.2. Resultados de la la red neuronal de Hinton

En este método para la reducción y caracterización de imágenes sólo se usaron 70 imágenes de 2588×1958 pixeles del conjunto original, 35 por cada clase. Para la realización de los experimentos este conjunto se dividido como se muestra en la Figura 4.7, donde se obtuvieron únicamente 2 conjuntos etiquetados como $RN - R1$ y $RN - R2$ respectivamente. Como se mencionó en la Sección 3.3.2, la red neuronal se modifico para poder trabajar con 3, 4, 5 y 6 capas, además se modificaron algunos valores para obtener mejores resultados. En la Tabla 4.23, se muestra los valores correspondientes para cada capa.

Los valores propuestos para cada una de las capas se eligieron después de haber realizado una serie de experimentos y con los cuales se obtuvo un error menor de entrenamiento y prueba con respecto de los otros y la variación del número de capas fue para comprobar si se obtenía mejores resultados. Los experimentos elegidos se etiquetaron como $E1, E2, \dots, E8$, los cuales fueron realizados para cada conjunto. Las Tablas 4.24 y 4.25 muestran los resultados de los errores para las imágenes sin procesamiento para los conjuntos $RN - R1$ y $RN - R2$. Y en la Tablas 4.26 y 4.27 se muestran los resultados de los errores para los conjuntos $RN - R1$ y $RN - R2$ con imágenes con procesamiento.

Tabla 4.23: Número y valores de las capas de la red neuronal.

	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
Número de capas	3	3	4	4	5	5	5	6
Valores	2000,1000, 755	2000,1000, 755	2048,1024, 700, 512	1800,1500, 1200, 1000	2800,1800, 1500, 250 10	2900,1900, 999, 512 15	4095,2048, 1024, 700 512	2000,1000, 700, 500 250,50
Número de iteraciones entrenamiento	10	25	10	20	10	10	10	10
Número de Iteraciones ajuste	100	100	100	100	200	100	100	100

Tabla 4.24: Valores de los errores de entrenamiento y prueba para las imágenes sin procesamiento para el conjunto $RN - R1$.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
Entrenamiento	26.01	28.38	41.30	33.36	41.3	23.97	27.32	41.30
Prueba	33.04	38.90	47.61	43.57	47.61	36.11	37.10	47.61

Tabla 4.25: Valores de los errores de entrenamiento y prueba para las imágenes sin procesamiento para el conjunto $RN - R2$.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
Entrenamiento	165.33	15.71	220.84	220.84	161.88	194.27	184.59	193.57
Prueba	223.59	226.53	255.91	255.88	256.09	239.64	242.22	240.81

Tabla 4.26: Valores de los errores de entrenamiento y prueba para las imágenes con procesamiento para el conjunto $RN - R1$.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
Canny								
Entrenamiento	2.73	0.02	9.15	0.01	3.97	14.88	6.2	18.70
Prueba	36.58	43.28	36.55	44.99	52.53	52.94	54.40	36.42
Range-filter								
Entrenamiento	2.40	1.42	4.27	1.90	2.92	4.44	4.16	3.21
Prueba	3.76	3.09	2.65	4.01	4.80	4.51	4.42	4.70
Ecuación del histograma								
Entrenamiento	38.35	38.95	64.26	37.54	64.26	64.26	48.50	46.91
Prueba	52.70	54.62	68.22	54.46	68.22	68.22	57.26	56.63
Binarización								
Entrenamiento	623.37	607.52	622.93	615.68	631.61	619.69	619.48	611.55
Prueba	673.17	641.08	674.97	664.30	978.31	663.57	668.24	663.32

Tabla 4.27: Valores de los errores de entrenamiento y prueba para las imágenes con procesamiento para el conjunto $RN - R2$.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
Canny								
Entrenamiento	489.28	16.70	695.76	54.58	480.39	1051.70	784.49	982.15
Prueba	1413.31	1456.91	1094.06	1068.24	1448	1735.54	1750.15	1098.24
Range-filter								
Entrenamiento	24.03	23.29	27.20	24.67	24.74	25.47	46.60	25.28
Prueba	35.69	35.24	40.54	36.84	38.36	37.15	26.30	35.85
Ecuación del histograma								
Entrenamiento	3371.33	3470.83	3423.98	3365.76	3489.33	3535.50	3457.32	34.22
Prueba	3399.43	3516.31	3456.25	3406.59	3515.02	3566.02	3486.34	3453.96
Binarización								
Entrenamiento	3398.70	3411.03	3444.62	3428.87	3419.90	3429.97	3425.44	3402.78
Prueba	3706.06	3714.52	3757.53	3786.85	3759.54	3737.98	3746.08	3725.81

Como resultados de las experimentaciones se obtuvieron las reconstrucciones para cada uno de los conjuntos. La Figura 4.8 muestra los resultados para el conjunto ($RN - R1$) y la Figura 4.9 para el conjunto ($RN - R2$), las imágenes superiores muestran las imágenes originales.

Los resultados de la clasificación es el promedio de 5 corridas.

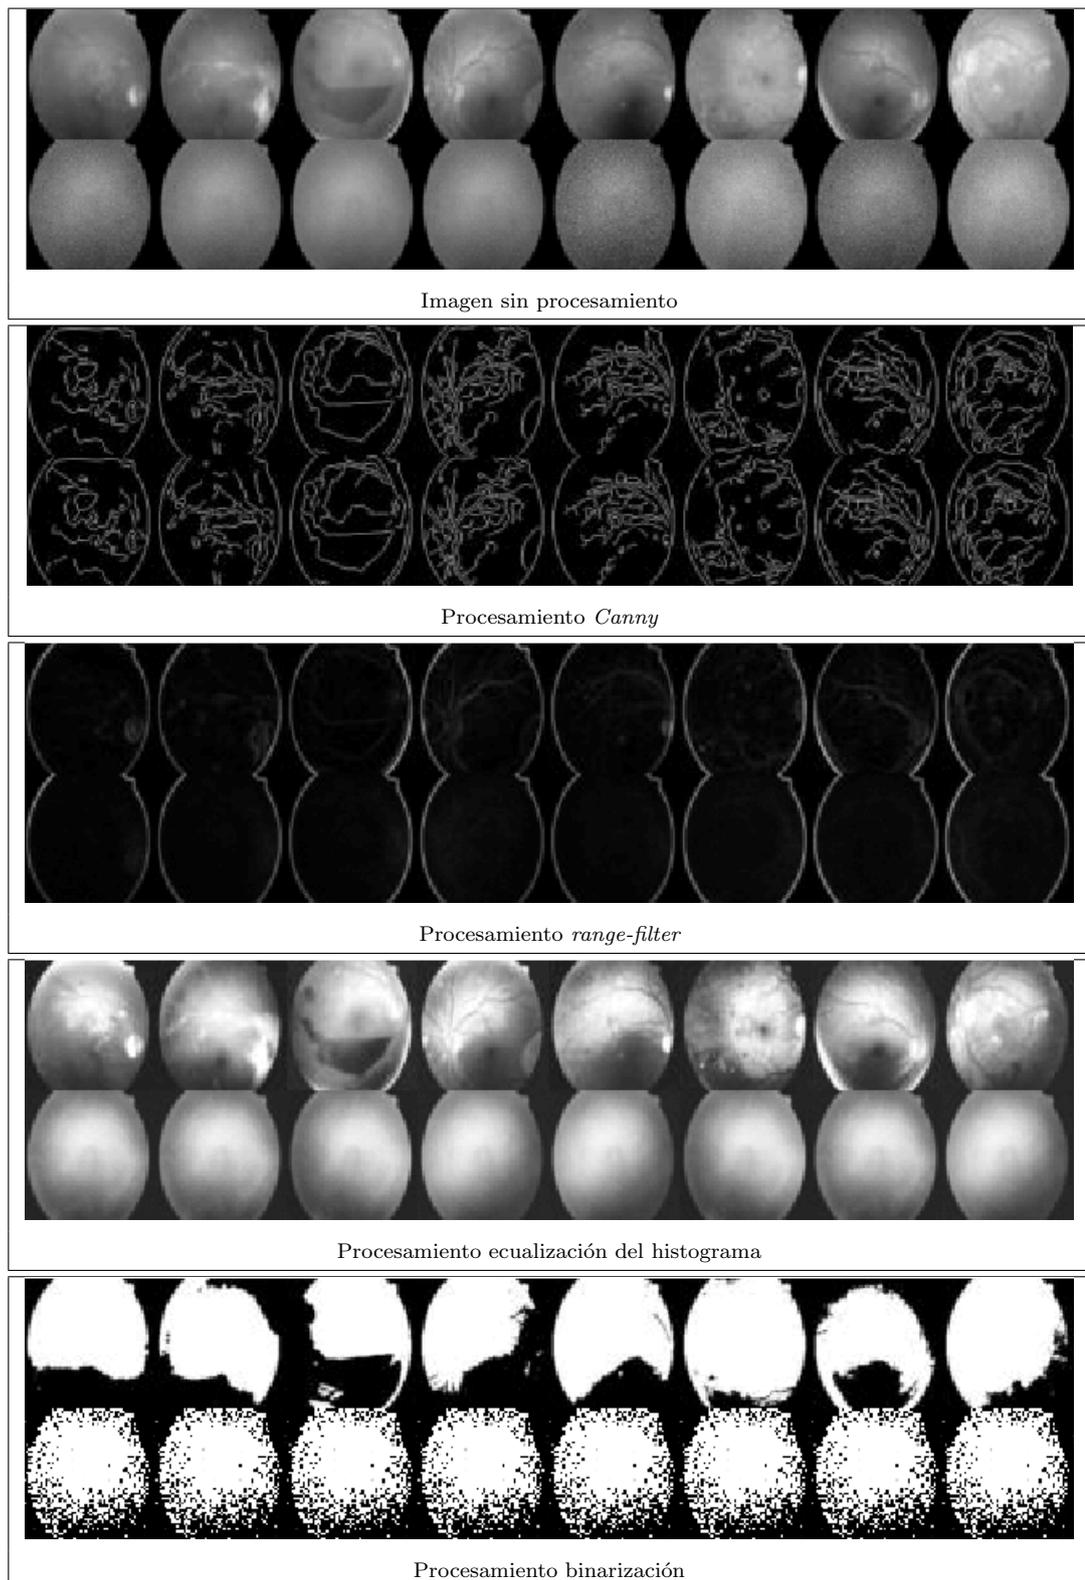
Resultados de la clasificación con imágenes sin procesamiento

Las Tablas 4.28 y 4.29 muestran los resultados con imágenes originales para los conjuntos $RN - R1$ y $RN - R2$, de 56×56 y 128×128 pixeles respectivamente, estos experimentos fueron realizados con los parámetros por default. Para el conjunto $RN - R1$ los mejores resultados son de 55,3% con todas las métricas para el conjunto $E2$ con el algoritmo naive Bayes, para este experimento se usó 755 características. El conjunto $RN - R2$ obtuvo 50,4% para todas las métricas como mejor resultado con el algoritmo k -nn con el conjunto $E2$ y el mismo número de características que el anterior.

Los resultados de la clasificación con los parámetros modificados se muestran en las Tablas 4.30 y 4.31, el conjunto $RN - R1$ reportó el mejor resultado con el conjunto $E8$ con 67% de *precision* usando 50 características con el algoritmo *SVMs*, los parámetros modificados son los siguientes: $c = 2$, $kernel = PolyKernel-E$ 3,0, $numFolds = 5$ y $randomSeed =$ aleatorio, el algoritmo anterior con los mismos parámetros también obtuvo el mejor resultado de 61,4% de *precision* para el conjunto $RN - R2$, usando 755 características con el conjunto $E2$.

Resultados de la clasificación con imágenes con procesamiento

Los resultados de la clasificación de las imágenes con técnicas de procesamiento se presentan en las Tablas: 4.32, 4.34, 4.33, 4.35, a continuación se detalla el resultado de

Figura 4.8: Resultados de las reconstrucciones para el conjunto $RN - R1$.

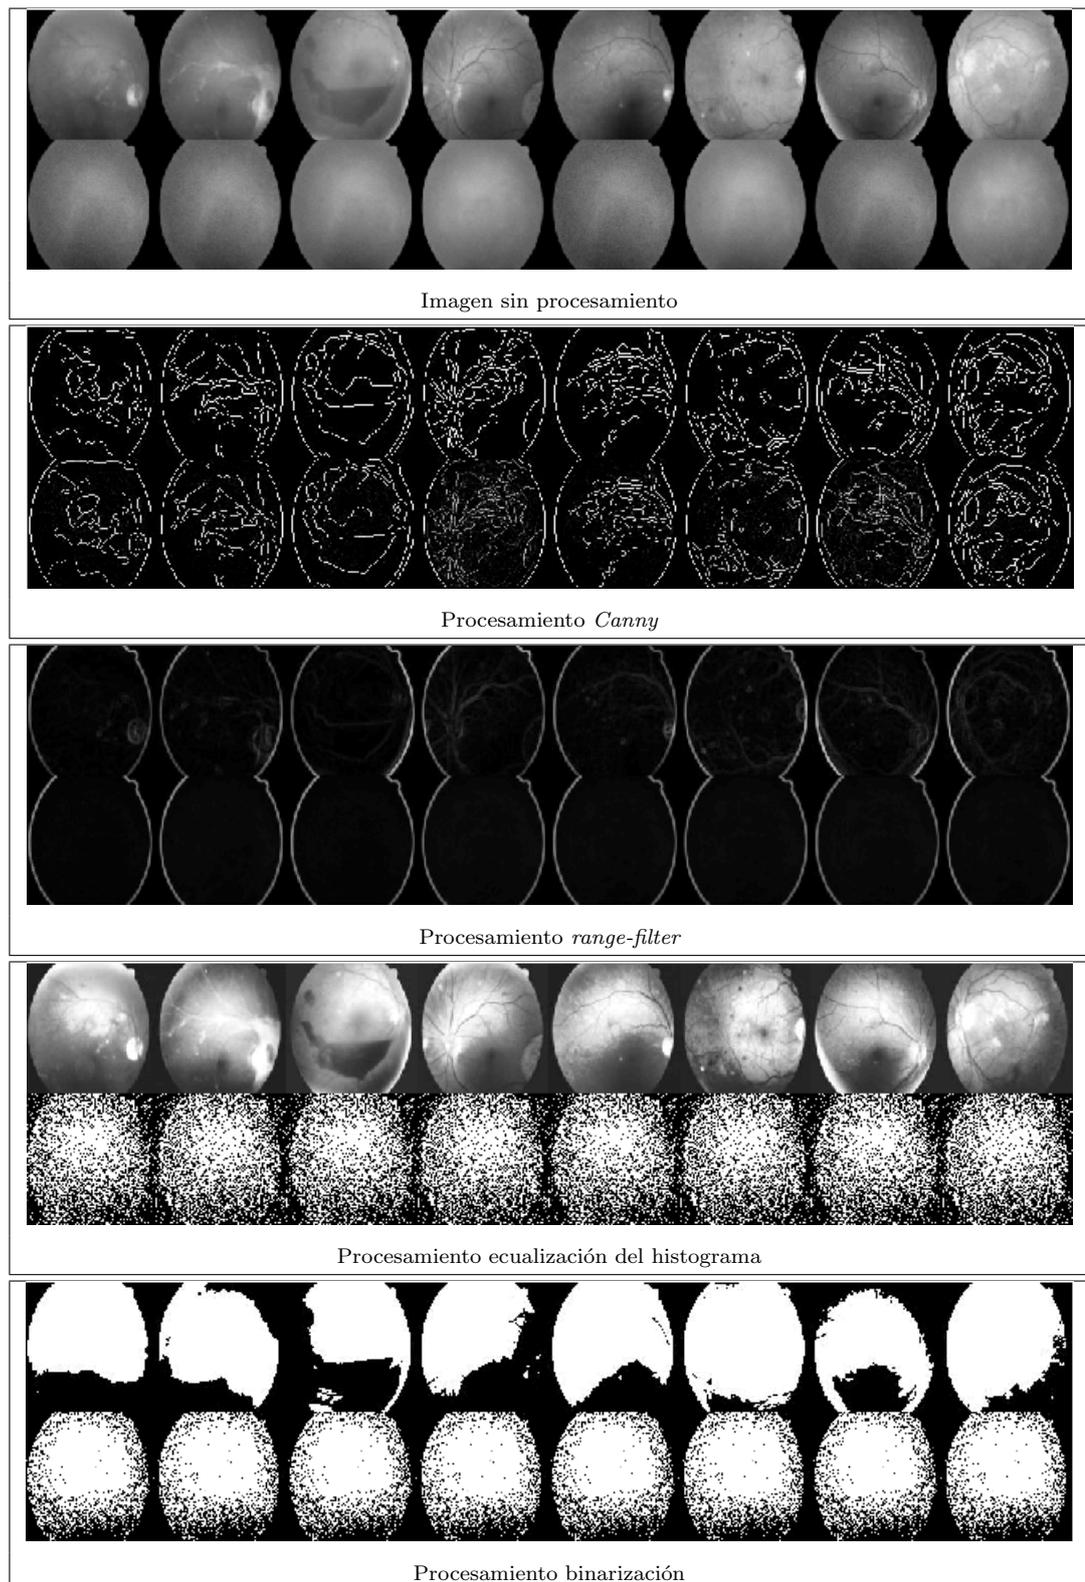
Figura 4.9: Resultados de las reconstrucciones para el conjunto $RN - R2$.

Tabla 4.28: Promedios% para el conjunto $RN - R1$ con imágenes sin procesamiento, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	48	48	43.3	37.2	49.7	50	45.7	46.8
k -nn	52.9	49.8	37.7	50	49.5	43.8	40.5	38.3
NB	43.7	55.3	44.7	53.8	48.5	40.9	34.5	37.7
RN	51.7	46.7	45.3	52	40.7	40.7	39.3	51
SVMs	45.8	47	46.5	43.7	46	37.8	38.8	48.5
<i>Precision</i>								
AD	47.8	46.2	37.1	36.3	24.9	25	35.8	30.1
k -nn	52.9	49.8	37.6	50	49.5	43.8	40.5	38.2
NB	43.4	55.3	44.3	53.9	48.3	40.3	33.5	36.5
RN	51.7	46.7	45.3	52	40.5	40.4	38.9	51
SVMs	45.8	47	46.3	43.7	45.6	37.4	38.7	48.5
<i>Recall</i>								
AD	48	48	44.3	37.2	49.7	50	45.7	46.8
k -nn	52.9	49.8	37.7	50	49.5	43.8	40.5	38.3
NB	43.7	55.3	44.7	53.8	48.5	40.8	34.5	37.7
RN	51.7	46.7	45.3	52	40.7	40.7	39.3	51
SVMs	45.8	47	46.5	43.7	46	37.8	38.8	48.5
<i>F-measure</i>								
AD	47.7	43.7	35.3	35.9	33.2	33.3	33.8	33.1
k -nn	52.7	49.8	37.6	49.7	49.3	43.8	40.4	38.2
NB	43.1	55.3	44	52.9	47.6	39.9	33.4	36.3
RN	51.5	46.6	45.2	51.8	40.4	40.3	38.8	50.9
SVMs	45.6	46.8	46.3	43.6	45.1	37.3	38.7	47.9

Tabla 4.29: Promedios% para el conjunto $RN - R2$ con imágenes sin procesamiento, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	42.8	48.8	43.8	46.7	50	50	44.2	46.2
k -nn	39.2	50.4	40	40.5	35.3	48.7	47.8	37.3
NB	39.3	49.2	32.7	41.7	38.8	40.8	41.5	36.8
RN	40.4	45.3	45.2	35.3	41.3	42.7	41.8	42
SVMs	36.8	40.3	42.2	43	40.5	38.2	42	43.2
<i>Precision</i>								
AD	42.5	48.8	38.7	46	25	25	38.6	33.1
k -nn	38.8	50.4	39.9	40.5	34.7	48.7	47.8	37.2
NB	38.9	49.1	32.5	41.2	38	39.9	41	36.5
RN	40	45.3	48.6	34.9	41	42.4	41.7	41.8
SVMs	36.6	40.3	42	42.9	40.3	37.9	41.9	42.9
<i>Recall</i>								
AD	42.8	48.8	43.8	46.7	50	50	44.2	46.2
k -nn	39.2	50.4	40	40.5	35.3	48.7	47.8	37.3
NB	39.3	49.2	32.7	41.7	38.8	40.8	41.5	36.8
RN	40.4	45.3	45.2	35.3	41.3	42.7	41.8	42
SVMs	36.8	40.3	42.2	43	40.5	38.2	42	43.2
<i>F-measure</i>								
AD	42.2	48.6	36.9	44.3	33.3	33.3	37.1	34.1
k -nn	38.7	50.2	39.9	40.4	34.6	48.2	47.8	37.2
NB	38.8	48.9	32.5	40.9	37.8	39.6	40.7	36.5
RN	39.7	45.1	44.5	34.7	41	42.1	41.5	41.6
SVMs	36.6	40.3	42	42.9	40.3	37.9	41.9	42.9

Tabla 4.30: Promedios % para el conjunto $RN - R1$ sin procesamiento, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	49.7	54.3	47.4	46.7	50	50	50.7	49.7
k -nn	52	54	44.3	48	49.3	55	41.7	48.3
NB	50	53.7	49.3	52	43.7	41.7	50	42.3
RN	50.3	63	47.3	52.3	41.3	46.3	43.7	52.3
SVMs	53.7	50	46.3	51.3	47.7	43	47.7	66.7
<i>Precision</i>								
AD	49.8	54.4	46.7	46.6	50	50	50.8	49.6
k -nn	52	54.1	44.2	47.9	49.6	55	41.6	48.2
NB	50	53.7	49.3	52	43.5	41.3	25	42.2
RN	50.5	63.1	47.1	52.4	41.2	46.1	43.6	52.4
SVMs	53.7	49.6	46.3	51.4	47.3	42.6	47.7	67
<i>Recall</i>								
AD	49.7	54.3	47.4	46.7	50	50	50.7	49.7
k -nn	52	54	44.3	48	49.3	55	41.7	48.3
NB	50	53.7	49.3	52	43.7	41.7	50	42.3
RN	50.3	63	47.3	52.3	41.3	46.3	43.7	52.3
SVMs	53.7	50	46.3	51.3	47.7	43	47.7	66.7
<i>F-measure</i>								
AD	44.8	54.2	45.3	46.4	47.9	49.3	49.4	48.3
k -nn	51.9	53.7	43.9	47.8	49.3	54.9	41.6	47.6
NB	50	53.5	49.2	51.7	43.3	41	33.3	42.2
RN	49.2	62.9	46.7	52.1	41.1	45.9	43.1	52.1
SVMs	53.6	47	46.2	50.5	46	42.3	47.6	66.5

Tabla 4.31: Promedios % para el conjunto $RN - R2$ sin procesamiento, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	48.7	52.7	48.7	47.7	50	50	49.7	48.7
k -nn	41.7	56.7	51.7	45	49.3	47.7	52.7	50.7
NB	46.3	49	50	50	50	49	45.7	44
RN	48.3	50	48.7	50	45.4	45.7	52.3	44.7
SVMs	51	61.3	45.3	47.6	43.3	48.7	51.3	43.7
<i>Precision</i>								
AD	48.4	52.7	48.3	47.5	50	50	43.2	48.6
k -nn	40.8	56.7	51.7	45	49.3	47.7	52.8	50.7
NB	46.3	49	25	25	25	49	45.5	43.9
RN	47.8	50	48.5	50	45.3	45.6	52.3	44.6
SVMs	51	61.4	45.3	47.6	43.2	48.6	51.3	43.6
<i>Recall</i>								
AD	48.7	52.7	48.7	47.7	50	50	49.7	48.7
k -nn	41.7	56.7	51.7	45	49.3	47.7	52.7	50.7
NB	46.3	49	50	50	50	49	45.7	44
RN	48.3	50	48.7	50	45.4	45.7	52.3	44.7
SVMs	51	61.3	45.3	47.6	43.3	48.7	51.3	43.7
<i>F-measure</i>								
AD	47.7	52.5	47	46.2	48.9	48.9	36.2	48.1
k -nn	40.4	56.6	51.5	44.9	49.3	47.7	52.2	50.6
NB	46.2	48.9	33.3	33.3	33.3	48.9	45.4	43.9
RN	46.2	49.8	47.5	48.7	45	45.6	52.2	44.5
SVMs	50.9	61.3	45.3	47.6	43	48.5	51	43.4

cada técnica, dichos experimentos fueron realizados con los parámetros por default. La técnica *Canny* obtuvo el mejor resultado con el conjunto *E2* con 83,1 de *precision* con árboles de decisión, usando 755 características; *range filter* obtuvo 64% con todas las métricas, con el conjunto *E4* y el algoritmo de redes neuronales, usando 1000 características; *SVMs* obtuvo el mejor resultado con 57,9% de *precision* para ecualización del histograma con el conjunto *E4* usando 1000 características y la técnica de binarización con el algoritmo *k-nn* y el conjunto *E7* usando 512 características obtuvo 56,6% de *precision*.

Las Tablas 4.40, 4.42, 4.41 y 4.43, muestran los resultados de la clasificación con los parámetros modificados del conjunto *RN – R1*.

El algoritmo árboles de decisión con el conjunto *E2* usando 755 características obtuvo 82,1% de *precision* para la técnica *Canny*, con los siguientes parámetros modificados: *confidenceFactor* = 0,25, *minNumObj* = 3, *numFolds* = 4, *seed* = aleatorio; *range filter* obtuvo 66,1% de *precision* como mejor resultado con el algoritmo naive Bayes y el conjunto *E1* usando 755 características, los parámetros modificados son: *useKernelEstimator* = *true* y *useSupervisedDiscretization* = *false*; ecualización del histograma obtuvo 61% de *precision* con el conjunto *E4* y el algoritmo *k-nn* usando 1000 características, los parámetros modificados son: *KNN* = 5, *nearestNeighbourSearchAlgorithm* = *LinearNNSearch* y *distanceFunction* = *ManhattanDistance* y la técnica de binarización con el conjunto *E7* y el mismo algoritmo de la técnica anterior obtuvo 58,6% de *precision*, usando 512 características con los siguientes parámetros modificados: *KNN* = 1, *nearestNeighbourSearchAlgorithm* = *LinearNNSearch* y *distanceFunction* = *ManhattanDistance*.

Para el conjunto *RN – R2*, los resultados de la clasificación con parámetros por defecto se muestran en las Tablas 4.36, 4.38, 4.37 y 4.39. El mejor resultado para *Canny*

fue 66,3 % y para ecualización del histograma 55,3 % ambos para la métrica de *precision* con el algoritmo *k-nn* y el conjunto *E4* usando 1000 características; *range filter* obtuvo 76,8 % de *precision*, con el algoritmo naive Bayes y conjunto *E8* usando 50 características; *k*-vecinos más cercanos obtuvo 53,4 de *precision* para la técnica de binarización con el conjunto *E5* usando 10 características.

Los resultados de la clasificación con los parámetros modificados se reportan en las Tablas 4.44, 4.46, 4.45 y 4.47. La técnica *Canny* obtuvo 76,1 % de *precision* con el conjunto *E6* y árboles de decisión, usando 15 características, los parámetros que se modificaron son los siguientes: *confidenceFactor* = 0,5, *minNumObject* = 4, *numFolds* = 5, *reducedErrorPruning* = *true*, *seed* = aleatorio, *useLaplace* = *true*; naive Bayes obtuvo 76,8 % de *precision* para *range filter* con el conjunto *E8* usando 50 características, con los siguiente parámetros modificados: *useKernelEstimator* = *true* y *useSupervisedDiscretization* = *false*; ecualización del histograma obtuvo 55.2 de *precision* como mejor resultado con el conjunto *E4* y *k-nn*, usando 1000 características, los parámetros modificados son: *KNN* = 1, *nearestNeighbourSearchAlgorithm* = *LinearNNSearch* y *distanceFunction* = *ManhattanDistance* y con el mismo algoritmo de la técnica anterior se obtuvo el 54,3 % de *precision* para la técnica de binarización, con el conjunto *E5* usando 10 características con los siguientes parámetros modificados: *KNN* = 1, *nearestNeighbourSearchAlgorithm* = *BallTree* y *distanceFunction* = *EuclideanDistance*.

Comparación de los mejores algoritmos con la métrica *F-measure*

Para observar el desempeño de los mejores algoritmos, las siguientes Figuras 4.10 y 4.11, muestra el Promedio % de la métrica *F-measure* para todos los conjuntos.

En la gráfica 4.10 a), se muestran los resultados con los parámetros modificados del

Tabla 4.32: Promedios % para el conjunto *RN – R1* con procesamiento *Canny*, con parámetros por default.

Experimento	<i>E1</i>	<i>E2</i>	<i>E3</i>	<i>E4</i>	<i>E5</i>	<i>E6</i>	<i>E7</i>	<i>E8</i>
<i>Accuracy</i>								
AD	46.4	83	55.3	59.3	49.7	51.7	47.3	60.8
<i>k</i> -nn	40.5	48.5	62.8	53.8	57.2	52.5	57.2	52.5
NB	58.9	65.2	56	54.8	27.7	52.8	52.5	59.2
RN	54.3	56.7	55	57.3	53	53.3	57.3	62.7
SVMs	57.2	54.3	51.2	62	38.8	50.2	61	61.7
<i>Precision</i>								
AD	38.1	83.1	55.5	60	45.7	51.9	47.3	61.1
<i>k</i> -nn	40.4	48.4	62.9	53.9	57.2	52.5	57.2	52.5
NB	58.9	65.2	56.1	54.9	27.5	54.1	52.7	60.5
RN	54.4	56.7	55.1	57.4	53	53.4	57.4	62.8
SVMs	57.2	54.3	51.2	62.1	37.9	50.9	61.2	61.8
<i>Recall</i>								
AD	46.4	83	55.3	59.3	49.7	51.7	47.3	60.8
<i>k</i> -nn	40.5	48.5	62.8	53.8	57.2	52.5	57.2	52.5
NB	58.9	65.2	56	54.8	27.7	52.8	52.5	59.2
RN	54.3	56.7	55	57.3	53	53.3	57.3	62.7
SVMs	57.2	54.3	51.2	62	38.8	50.2	61	61.7
<i>F-measure</i>								
AD	36.4	83	55.1	59	35.8	51.1	47.3	60.6
<i>k</i> -nn	40.4	48.1	62.8	53.6	57.1	52.5	57.2	52.5
NB	58.7	65.2	55.7	52.9	27.5	49.2	51.7	57.9
RN	54.2	56.6	54.7	57.2	52.9	53.2	57.2	62.6
SVMs	57.1	54.3	51.1	62	37.8	45.7	60.8	61.6

Tabla 4.33: Promedios % para el conjunto $RN - R1$ con procesamiento ecualización del histograma, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	47.5	43.7	44.3	46.8	48.2	50	46	46.7
k -nn	49.8	43.2	48	40.8	50.2	48.5	53	47.2
NB	49.7	52.5	36.8	48.2	42.1	44.7	47.3	43.8
RN	51	48.7	47.7	53.7	47.2	43.5	44.7	44.2
SVMs	50.7	48.3	50.5	57.7	44.2	42	43.2	47.5
<i>Precision</i>								
AD	47.4	42.1	44.3	46.6	35.3	25	41.8	37.4
k -nn	49.8	43	48	40.8	50.2	48.5	53	47.1
NB	49.7	52.5	35.6	48.1	41.2	44.2	47.1	37.7
RN	51	48.6	47.6	53.7	47.1	43.4	44.4	43.9
SVMs	50.7	48.3	50.5	57.9	44	41.8	43.1	47.5
<i>Recall</i>								
AD	47.5	43.7	44.3	46.8	48.2	50	46	46.7
k -nn	49.8	43.2	48	40.8	50.2	48.5	53	47.2
NB	49.7	52.5	36.8	48.2	42.1	44.7	47.3	43.8
RN	51	48.7	47.7	53.7	47.2	43.5	44.7	44.2
SVMs	50.7	48.3	50.5	57.7	44.2	42	43.2	47.5
<i>F-measure</i>								
AD	47.2	40.8	44.2	46.3	34.1	33.3	39.9	35.4
k -nn	49.4	42.9	47.8	40.8	50.1	48.5	52.9	47.1
NB	49.5	52.5	35.4	52.9	40.9	43.9	46.9	35.5
RN	51	48.4	47.2	53.4	46.9	43	44.2	43.6
SVMs	50.5	48.2	50.4	57.4	43.8	41.5	43	47.4

Tabla 4.34: Promedios% para el conjunto $RN - R1$ con procesamiento *range-filter*, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	50.8	47.3	43.2	58.9	49.4	50	57.8	56
k -nn	47.2	54.8	56.3	54.4	46.8	54.8	61.2	46.8
NB	55	51.5	49.5	52.7	46.5	51	53	50.3
RN	57	55.3	55.4	64	56.2	48.8	58.7	55.8
SVMs	52.5	59.2	49.7	49.7	48.5	49	45.3	52
<i>Precision</i>								
AD	50.9	47.3	43	58.9	49.3	25	58	56.2
k -nn	47.1	54.9	56.7	54.4	46.7	54.8	61.2	46.8
NB	60.1	51.6	48.4	53	43.7	52.5	58.4	50.5
RN	57.2	55.4	55.4	64	56.9	49.3	58.9	55.9
SVMs	52.5	59.2	49.7	49.6	48.1	48.2	45.1	52.1
<i>Recall</i>								
AD	50.8	47.3	43.2	58.9	49.4	50	57.8	56
k -nn	47.2	54.8	56.3	54.4	46.8	54.8	61.2	46.8
NB	55	51.5	49.5	52.7	46.5	51	53	50.3
RN	57	55.3	55.4	64	56.2	48.8	58.7	55.8
SVMs	52.5	59.2	49.7	49.7	48.5	49	45.3	52
<i>F-measure</i>								
AD	50.8	47.2	42.8	58.8	48.8	33.3	57.7	55.5
k -nn	46.9	54.8	55.8	54.2	46.2	54.8	61.2	46.7
NB	48.4	50.3	41	52.9	39.7	43.4	44.2	46.7
RN	56.8	55.3	55.1	64	55	45.9	58.3	55.7
SVMs	52.4	59.2	49.6	49.5	47	44.8	44.8	50.9

Tabla 4.35: Promedios% para el conjunto $RN - R1$ con procesamiento de binarización, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	46.7	43.3	44.5	46.7	50	50	47.7	46.8
k -nn	40.3	47.3	36.3	51.2	51.5	37.8	56.5	42.5
NB	52	42	43.7	50.7	41.2	41	40.3	40.1
RN	45.7	40.7	40.7	46.3	41.2	44.2	42.3	43.5
SVMs	43.5	42.2	44	43.2	39	43	42.7	48.8
<i>Precision</i>								
AD	36.8	42.1	36.5	40.8	25	25	24.4	25
k -nn	40.2	47.3	36.3	51.2	51.5	37.6	56.6	42.3
NB	52	41.5	41.7	50.6	40.3	40.4	39.8	39.8
RN	45.4	40.4	40.4	46.1	40.3	43.7	42.3	43.4
SVMs	43.4	42	44	42.9	38.5	42.8	42.6	49.8
<i>Recall</i>								
AD	46.7	43.3	44.5	46.7	50	50	47.7	46.8
k -nn	40.3	47.3	36.3	51.2	51.5	37.8	56.5	42.5
NB	52	42	43.7	50.7	41.2	41	40.3	40.1
RN	45.7	40.7	40.7	46.3	41.2	44.2	42.3	43.5
SVMs	43.5	42.2	44	43.2	39	43	42.7	48.8
<i>F-measure</i>								
AD	36	38.8	34.6	36.4	33.3	33.3	32.3	32.1
k -nn	40.2	47.2	36.2	51.1	51.2	37.4	56.4	42.2
NB	51.9	41.2	40.3	52.9	40.1	40.2	39.5	39.6
RN	44.8	40	40.3	45.6	40.1	43.2	42.1	43.2
SVMs	43.3	41.9	43.8	42.7	38.3	42.6	42.4	49.5

Tabla 4.36: Promedios% para el conjunto $RN - R2$ con procesamiento *Canny*, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	59.4	60.2	56.5	55.8	47.8	51	47.5	51.2
k -nn	54.3	62.3	61.7	66.3	58.3	55	52.5	55.7
NB	56	61.2	55.8	61.3	44.8	47.7	44.7	51.5
RN	57.7	64.4	52.3	65.3	52	55.8	46	58
SVMs	60.7	62	51.2	64.2	49.3	47	50.2	51.5
<i>Precision</i>								
AD	59.4	60.8	56.6	55.9	42.3	59.6	47.5	51.1
k -nn	54.4	62.4	61.8	66.5	58.4	55.2	52.6	55.7
NB	56	61.5	56	61.6	44.7	47.7	44.6	51.6
RN	57.7	64.5	52.3	65.5	52	55.9	45.9	58
SVMs	60.7	62.1	51.2	64.2	49.2	46.8	50.2	51.5
<i>Recall</i>								
AD	59.4	60.2	56.5	55.8	47.8	51	47.5	51.2
k -nn	54.3	62.3	61.7	66.3	58.3	55	52.5	55.7
NB	56	61.2	55.8	61.3	44.8	47.7	44.7	51.5
RN	57.7	64.4	52.3	65.3	52	55.8	46	58
SVMs	60.7	62	51.2	64.2	49.3	47	50.2	51.5
<i>F-measure</i>								
AD	59.3	59.4	56.4	55.7	36.4	38.7	47.3	50.9
k -nn	54.3	62.3	61.6	66.3	58.3	54.6	52.1	55.6
NB	56	60.9	55.7	52.9	43.9	47.4	44.6	51.3
RN	57.6	64.3	52.3	65.2	51.8	55.8	45.8	58
SVMs	60.7	62	51.1	64.1	48.2	46.7	50	51.4

Tabla 4.37: Promedios % para el conjunto $RN - R2$ con procesamiento ecualización del histograma, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	46.7	47.2	49	46.7	50	46.3	44.3	46.2
k -nn	46	45.2	41.3	55	41.5	41.5	43.5	42.9
NB	42.4	48	45.8	43	38.7	41.2	45.2	38.7
RN	46	47.3	39.3	45	39.3	42.5	43.7	40.5
SVMs	43.7	43.8	42.7	42.2	39.7	42.7	43.7	42.3
<i>Precision</i>								
AD	24.9	26.2	28.5	26.9	25	26.5	25.8	29.2
k -nn	46	45.2	41.2	55.3	40.5	40.6	42.5	41.8
NB	42.2	48	44.8	42.8	37.7	40.6	45.1	41
RN	45.9	47.1	39	44.7	39	42.4	43.3	40.1
SVMs	43.5	43.7	42.5	42	39.5	42.4	43.6	42.3
<i>Recall</i>								
AD	46.7	47.2	49	46.7	50	46.3	44.3	46.2
k -nn	46	45.2	41.3	55	41.5	41.5	43.5	42.9
NB	42.4	48	45.8	43	38.7	41.2	45.2	38.7
RN	46	47.3	39.3	45	39.3	42.5	43.7	40.5
SVMs	43.7	43.8	42.7	42.2	39.7	42.7	43.7	42.3
<i>F-measure</i>								
AD	32.1	32.5	33.6	32.6	33.3	32.3	31.7	33
k -nn	46	45.1	41.1	54.5	39.7	39.9	41.3	40.9
NB	42.1	47.9	42.9	52.9	37.6	40.2	45	38.1
RN	45.3	46.7	38.9	44.7	38.8	42.2	42.9	40
SVMs	43.3	43.5	42.4	41.9	39.4	42.3	43.4	42.2

Tabla 4.38: Promedios% para el conjunto $RN - R2$ con procesamiento *range-filter*, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	53	56.8	47.5	46.7	50	47.7	54.3	66.3
k -nn	52.7	53.8	47.2	37.3	45.4	50.2	52	54.5
NB	46.5	61.9	62.8	46.8	44.2	60.7	62.2	56.7
RN	54.7	65.3	55	51	55.5	60.3	50.4	61.3
SVMs	54.2	46.3	57.2	51.7	46.5	58.3	51.7	55
<i>Precision</i>								
AD	53	56.9	46.9	46.5	25	44.7	54.5	66.4
k -nn	52.7	54.1	47.1	37.1	45.3	50.2	52.1	54.5
NB	45	67.3	70.4	40.5	42.8	68.6	68.1	76.8
RN	54.7	65.5	56.2	51	55.9	61.1	50.3	62.6
SVMs	54.2	45.8	57.4	51.6	46.4	60.8	51.7	55.7
<i>Recall</i>								
AD	53	56.8	47.5	46.7	50	47.7	54.3	66.3
k -nn	52.7	53.8	47.2	37.3	45.4	50.2	52	54.5
NB	46.5	61.9	62.8	46.8	44.2	60.7	62.2	56.7
RN	54.7	65.3	55	51	55.5	60.3	50.4	61.3
SVMs	54.2	46.3	57.2	51.7	46.5	58.3	51.7	55
<i>F-measure</i>								
AD	53	56.6	46.1	46.3	33.3	39.7	53.9	66.3
k -nn	52.6	53.1	46.9	37	44.8	50.1	51.6	54.5
NB	42.6	58.5	59	52.9	41.3	56	58.8	46.6
RN	54.6	65.3	52.4	50.6	54.9	59.5	50	60.3
SVMs	54.1	45.3	56.8	51	45.8	56	51.1	52.9

Tabla 4.39: Promedios % para el conjunto $RN - R2$ con procesamiento de binarización, con parámetros por default.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	46.8	46.8	46	46.2	47.3	46.8	47.5	47
k -nn	32.7	46	41.7	47.5	53.2	44.8	52.2	49.7
NB	42.8	43.7	50.5	38.3	38.7	45.8	45.2	42.8
RN	44.3	41.7	43.7	48	42	43.7	40.7	42.7
SVMs	43	44.7	43.5	41.2	50	52.3	42.8	48.3
<i>Precision</i>								
AD	39.8	38.7	25.5	25	24.3	24.8	24.3	27
k -nn	32.6	45.9	41.6	47.5	53.4	44.4	52.3	49.6
NB	42.3	43.5	50.5	37.6	37.7	45.6	44.5	42.6
RN	44.3	41.6	43.3	47.8	41	43.5	40.2	42.6
SVMs	42.8	44.6	43.5	41	50	52.4	42.8	48.3
<i>Recall</i>								
AD	46.8	46.8	46	46.2	47.3	46.8	47.5	47
k -nn	32.7	46	41.7	47.5	53.2	44.8	52.2	49.7
NB	42.8	43.7	50.5	38.3	38.7	45.8	45.2	42.8
RN	44.3	41.7	43.7	48	42	43.7	40.7	42.7
SVMs	43	44.7	43.5	41.2	50	52.3	42.8	48.3
<i>F-measure</i>								
AD	35.7	35.3	32.1	31.8	32.1	32.1	32.2	32.8
k -nn	32.6	45.6	41.6	47.4	52.7	43.5	51.6	47.4
NB	41.8	43.4	50.4	52.9	37.5	45.2	43.7	42.4
RN	44	41.6	42.7	47.3	40.7	43.3	43.7	42.4
SVMs	42.6	44.4	43.3	40.9	49.8	52.3	38.9	48.3

Tabla 4.40: Promedios % para el conjunto $RN - R1$ con procesamiento *Canny*, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	66.7	82	54	59.7	51.7	55	52.3	60.7
k -nn	67.3	54.3	61.7	56	56.3	55.7	55.7	60.3
NB	58.7	67.3	59.3	58.7	50	56.3	53.7	58.4
RN	57.3	53.3	60.6	59.7	60	59	61	62.7
SVMs	63.7	55.3	60.3	61	61	57.3	61.7	63.7
<i>Precision</i>								
AD	67.8	82.1	54.3	59.8	52.5	55.1	52.3	60.8
k -nn	67.8	54.6	64.9	57.4	56.4	55.7	55.7	60.5
NB	58.8	67.4	59.5	58.7	25	61.3	55.7	63
RN	57.4	53.4	60.9	59.8	60.1	59	61.1	63.1
SVMs	63.8	55.3	60.3	61.1	61.2	65	62.6	63.9
<i>Recall</i>								
AD	66.7	82	54	59.7	51.7	55	52.3	60.7
k -nn	67.3	54.3	61.7	56	56.3	55.7	55.7	60.3
NB	58.7	67.3	59.3	58.7	50	56.3	53.7	58.4
RN	57.3	53.3	60.6	59.7	60	59	61	62.7
SVMs	63.7	55.3	60.3	61	61	57.3	61.7	63.7
<i>F-measure</i>								
AD	66.2	82	53.7	59.5	46.7	54.7	52.3	60.5
k -nn	67.1	53.6	61.4	53.9	56.2	55.7	55.6	60.2
NB	58.6	67.3	59.1	58.6	33.3	51.5	49.4	54.3
RN	57.2	53.2	60.5	59.5	59.8	59	60.9	62.5
SVMs	63.6	55.3	60.3	60.9	60.9	54.2	61	63.5

Tabla 4.41: Promedios % para el conjunto $RN - R1$ con procesamiento ecualización del histograma, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	52	48	50.3	50.7	49.3	50	48.7	48.3
k -nn	55	46.3	46	60.7	55.7	52.3	56	48.7
NB	52.3	51	48	54.7	45.7	50	50	49
RN	57.7	48.3	49.7	59.7	49	43.7	50.3	47.7
SVMs	55	49.7	49	55.3	47.7	44.3	49.6	45.3
<i>Precision</i>								
AD	52.7	47.6	50.5	50.7	49.1	50	48.5	48
k -nn	55	46.3	46	61	56	52.4	56.2	48.7
NB	52.5	51	48	54.7	45.6	25	25	31.4
RN	57.7	48.3	49.7	60.2	49	43.5	50.4	47.7
SVMs	55.2	49.7	49	55.4	47.7	44.1	49.6	45.3
<i>Recall</i>								
AD	52	48	50.3	50.7	49.3	50	48.7	48.3
k -nn	55	46.3	46	60.7	55.7	52.3	56	48.7
NB	52.3	51	48	54.7	45.7	50	50	49
RN	57.7	48.3	49.7	59.7	49	43.7	50.3	47.7
SVMs	55	49.7	49	55.3	47.7	44.3	49.6	45.3
<i>F-measure</i>								
AD	50.1	46.7	48.8	50.5	47.8	49.4	47.1	47.2
k -nn	54.8	46.2	45.9	60.4	55.3	51.9	55.7	48.6
NB	52.1	51	47.6	54.6	45.6	33.3	33.3	33.9
RN	57.6	47.9	48.9	59.2	48.8	43	50.2	47.6
SVMs	54.8	49.6	49	55.2	47.5	43.9	49.6	45.3

Tabla 4.42: Promedios % para el conjunto $RN - R1$ con procesamiento *range-filter*, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	53	51	49	63.7	52	50	57.7	59.3
k -nn	62.3	65	61	65	57.7	62.3	62.3	55.3
NB	55	55	49	54.3	51.7	53	53.7	51.3
RN	57	58	55	65	55.3	51.7	64.3	58.7
SVMs	59	58	55	63.3	51.7	52	61.3	56.3
<i>Precision</i>								
AD	53.1	51	49	63.9	48	50	57.8	60.2
k -nn	62.7	65	61.2	65.1	58.2	62.4	62.3	55.4
NB	66.1	57.9	46.7	56.9	58.8	62.5	63	51.3
RN	57.2	58.1	55	65.2	56	52	64.3	58.7
SVMs	59.1	58	56.2	63.4	51.6	53.7	61.3	56.5
<i>Recall</i>								
AD	53	51	49	63.7	52	50	57.7	59.3
k -nn	62.3	65	61	65	57.7	62.3	62.3	55.3
NB	55	55	49	54.3	51.7	53	53.7	51.3
RN	57	58	55	65	55.3	51.7	64.3	58.7
SVMs	59	58	55	63.3	51.7	52	61.3	56.3
<i>F-measure</i>								
AD	52.9	50.8	48.9	63.6	45.6	48.6	57.6	58.6
k -nn	62	65	60.8	65	56.9	62.3	62.3	55.3
NB	45.9	50.6	39.3	49.7	39.4	41.9	43.5	48.4
RN	56.7	57.9	54.6	64.9	54.4	50.4	64.3	58.6
SVMs	58.9	57.9	55.5	63.3	50.1	46.8	61.3	56

Tabla 4.43: Promedios % para el conjunto $RN - R1$ con procesamiento de binarización, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	49	48.6	47.7	49	50	50	49	50
k -nn	47.3	47.7	47.7	49	52.6	38.3	58.3	50
NB	46.7	45.3	50	50	50	50	50	50
RN	51	47.7	47.7	49.7	48.3	47	49	46
SVMs	46.5	52.6	44	43	49.7	50.7	42.3	46.7
<i>Precision</i>								
AD	49	48.6	47.2	48.7	50	50	48.9	50
k -nn	47.3	47.6	47.6	49	52.8	38	58.6	50.1
NB	46.6	45.3	25	50	50	50	25	25
RN	51.1	47.6	47.1	49.7	48.3	46.9	48.8	45.9
SVMs	46.5	52.6	43.9	42.8	49.7	50.8	41.4	46.6
<i>Recall</i>								
AD	49	48.6	47.7	49	50	50	49	50
k -nn	47.3	47.7	47.7	49	52.6	38.3	58.3	50
NB	46.7	45.3	50	50	50	50	50	50
RN	51	47.7	47.7	49.7	48.3	47	49	46
SVMs	46.5	52.6	44	43	49.7	50.7	42.3	46.7
<i>F-measure</i>								
AD	48.4	47.9	46.2	47.3	49	49.2	48	49
k -nn	47.1	47.4	47.4	49	52.3	37.8	58.1	48.1
NB	46.6	45.6	33.3	50	50	50	33.3	33.3
RN	49.9	45.2	46.2	48.4	48	46.7	48	45.6
SVMs	46.5	52.6	43.6	42.6	49.5	49.9	40.8	46.4

Tabla 4.44: Promedios % para el conjunto *RN – R2* con procesamiento *Canny*, con parámetros modificados.

Experimento	<i>E1</i>	<i>E2</i>	<i>E3</i>	<i>E4</i>	<i>E5</i>	<i>E6</i>	<i>E7</i>	<i>E8</i>
<i>Accuracy</i>								
AD	62.7	64.3	61.3	55	48.7	54.3	52.6	55.7
<i>k</i> -nn	55.3	63.7	62.3	70.3	66.7	56	53.7	59
NB	66.7	67	58.3	59	52.3	50	56	52.3
RN	61.7	63.7	53	64	55.7	60.3	49.3	62
SVMs	60.7	65.7	63	67	53	60.3	54.3	64
<i>Precision</i>								
AD	63.7	64.8	61.4	55.1	48.6	76.1	52.9	55.8
<i>k</i> -nn	55.4	63.7	62.3	70.4	66.8	56.2	54	59
NB	66.7	67.1	58.7	59.3	52.5	25	56	52.5
RN	61.7	63.9	53	64.1	55.7	60.5	49.3	62
SVMs	60.7	65.8	63.7	67.1	53	60.5	54.3	64.1
<i>Recall</i>								
AD	62.7	64.3	61.3	55	48.7	54.3	52.6	55.7
<i>k</i> -nn	55.3	63.7	62.3	70.3	66.7	56	53.7	59
NB	66.7	67	58.3	59	52.3	50	56	52.3
RN	61.7	63.7	53	64	55.7	60.3	49.3	62
SVMs	60.7	65.7	63	67	53	60.3	54.3	64
<i>F-measure</i>								
AD	62	64	61.3	55	48.3	42.3	52.2	55.5
<i>k</i> -nn	55.3	63.7	62.3	70.3	66.6	55.5	52.8	58.9
NB	66.6	67	57.8	58.7	51.8	33.3	55.9	51.9
RN	61.6	63.5	52.9	64	55.6	60.2	49	62
SVMs	60.7	65.6	62.5	67	52.9	60.1	54.3	64

Tabla 4.45: Promedios % para el conjunto $RN - R2$ con procesamiento ecualización del histograma, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	50	49	50	49.3	50	50	50	49.3
k -nn	47.7	49.3	47	55	44	43	45.3	43
NB	50	41.4	43.3	43	45.7	45.3	40.7	40.7
RN	50.3	47.3	45.3	50.7	47.3	44.7	47.3	46
SVMs	43.7	42	45.7	43.3	48	47.7	43.3	44.3
<i>Precision</i>								
AD	50	48.7	50	49.3	50	50	50	49.3
k -nn	47.6	49.2	47	55.2	43	42	44.4	42
NB	25	41.3	42.1	42.9	45.6	45.3	40.5	39.5
RN	50.7	46.8	44.9	51.2	47.3	44.6	47.3	45.6
SVMs	43	41.8	45.6	43.2	47.8	47.7	43	44.2
<i>Recall</i>								
AD	50	49	50	49.3	50	50	50	49.3
k -nn	47.7	49.3	47	55	44	43	45.3	43
NB	50	41.4	43.3	43	45.7	45.3	40.7	40.7
RN	50.3	47.3	45.3	50.7	47.3	44.7	47.3	46
SVMs	43.7	42	45.7	43.3	48	47.7	43.3	44.3
<i>F-measure</i>								
AD	48.9	47.3	49.1	48.7	48.5	48.9	48.5	48.5
k -nn	47.5	48.2	46.9	54.5	41.8	41	42.7	41
NB	33.3	41.2	41.1	42.9	45.6	45	40.3	39.4
RN	47.6	44.2	44.3	49.3	46.7	44.4	46.6	44.9
SVMs	42.2	41.7	45.5	43.2	47.4	47.5	42.6	43.9

Tabla 4.46: Promedios % para el conjunto $RN - R2$ con procesamiento *range-filter*, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	53.3	54.4	52.3	50.3	50	48.7	58	68
k -nn	61.3	55.3	69.3	54.6	51.3	64	53.3	63.3
NB	52.7	62.7	60.3	46.3	47	59.3	58	56.7
RN	62.4	65.3	56	53.3	58	62	56.7	62
SVMs	58	63.7	59	53.3	60.3	61.7	58.3	60.3
<i>Precision</i>								
AD	53.4	54.4	51.2	50.3	50	48.2	58.1	68.1
k -nn	61.3	55.6	69.5	54.8	51.3	64.5	53.5	63.6
NB	55.9	70.3	70.4	42.5	44.9	67.3	65.9	76.8
RN	62.4	65.6	58.2	53.4	58.7	62.6	56.7	63
SVMs	58.2	63.9	60.4	54.1	60.4	63.3	60.7	60.4
<i>Recall</i>								
AD	53.3	54.4	52.3	50.3	50	48.7	58	68
k -nn	61.3	55.3	69.3	54.6	51.3	64	53.3	63.3
NB	52.7	62.7	60.3	46.3	47	59.3	58	56.7
RN	62.4	65.3	56	53.3	58	62	56.7	62
SVMs	58	63.7	59	53.3	60.3	61.7	58.3	60.3
<i>F-measure</i>								
AD	53.1	54.2	47.5	49.3	48.9	45.2	57.9	68
k -nn	61.3	54.6	69.3	54.4	51.3	63.7	53	63.2
NB	45.2	58.8	54.8	38.4	40.8	54	52	46.6
RN	62.4	65.2	52.7	53.2	57.4	61.6	56.5	61.3
SVMs	57.8	63.5	57.6	50.8	60.2	60.5	56	60.2

Tabla 4.47: Promedios % para el conjunto $RN - R2$ con procesamiento de binarización, con parámetros modificados.

Experimento	$E1$	$E2$	$E3$	$E4$	$E5$	$E6$	$E7$	$E8$
<i>Accuracy</i>								
AD	49.7	49.7	48.7	50	50	47.7	48.7	48.7
k -nn	39	46	46.7	48	54	47	54	51
NB	50	47	50	50	46.3	46.3	50	45.7
RN	49	50.7	48	50	47.3	44.7	50	43
SVMs	52.7	44.3	45.4	43	49.7	49.7	43.4	46
<i>Precision</i>								
AD	49.7	49.6	48.6	50	50	47.3	48.6	48.6
k -nn	38.9	45.9	46.7	48	54.3	46.7	54.1	51.3
NB	25	47	25	25	46.3	446.3	25	45.6
RN	49	51	47.8	50	47.1	44.7	49.6	42.9
SVMs	42.2	44.3	44.9	42.5	49.7	49.7	43	45.9
<i>Recall</i>								
AD	49.7	49.7	48.7	50	50	47.7	48.7	48.7
k -nn	39	46	46.7	48	54	47	54	51
NB	50	47	50	50	46.3	46.3	50	45.7
RN	49	50.7	48	50	47.3	44.7	50	43
SVMs	52.7	44.3	45.4	43	49.7	49.7	43.4	46
<i>F-measure</i>								
AD	48.6	48.9	47.7	48.2	48.5	46.1	47.7	47.7
k -nn	38.8	45.8	46.6	47.9	53.5	45.3	53.8	48.9
NB	33.3	46.8	33.3	33.3	46.2	46.1	33.3	45.5
RN	48.6	46.9	47.2	49.5	46.5	43.9	49	42.8
SVMs	41.6	44.3	44	42.1	49.6	49.1	42.7	45.8

conjunto $RN - R1$ y los mejores subconjuntos fueron: *Canny* para todos los experimentos excepto $E6$, logrando resultados entre 57,1% y 83% con los algoritmos k -nn, naive Bayes, *SVMs*, y redes neuronales; *range filter* con los experimentos $E2$, $E4$, $E7$, E , obteniendo resultados entre 59,2% y 64% con los algoritmos *SVMs*, redes neuronales y k -nn. La segunda gráfica 4.10 b) muestra los resultados del conjunto $RN - R1$ con los parámetros modificados, los mejores subconjuntos son el conjunto sin procesamiento para los experimentos $E2$ con 62,9% y $E8$ con 66,5% con los algoritmos redes neuronales y *SVMs* respectivamente; *Canny* para todos los experimentos excepto $E6$ con resultados entre 60,9% y 82% con los algoritmos árboles de decisión, k -nn y *SVMs*; *range filter* para todos los experimentos excepto $E5$ y $E8$, con resultados entre 62% y 65% con los algoritmos k -nn y redes neuronales; ecualización del histograma para $E4$ con 60,4% y el algoritmo k -nn y para la técnica de binarización el experimento con mejor resultado fue $E4$ con 63,5% y algoritmo naive Bayes.

En la gráfica 4.11 c) se muestran los resultados de los parámetros por defecto para el conjunto $RN - R2$ y los subconjuntos que reportaron mejores resultados son: *Canny* para los experimentos $E1$, $E2$, $E3$ y $E4$ con porcentajes entre 60,7% y 66,3% con los algoritmos *SVMs*, redes neuronales y k -nn y *range filter* con los experimentos $E2$, $E3$, $E6$ y $E8$ con resultados entre 59% y 66,3% con los algoritmos redes neuronales, naive Bayes y árboles de decisión.

Y en la gráfica 4.11 d) los mejores resultados son obtenidos con los parámetros modificados para el conjuntos $RN - R2$, con los subconjuntos: el conjunto sin procesamiento con el experimento $E2$ con 61,3% y algoritmo *SVMs*; *Canny* para todos los experimentos excepto $E7$ logrando resultados entre 60,2% y 70,3% con los algoritmos naive Bayes, *SVMs*, k -nn y redes neuronales y *range filter* con resultados entre 60,2%

y 69,3% con los algoritmos redes neuronales, árboles de decisión *SVMs* y *k-nn*.

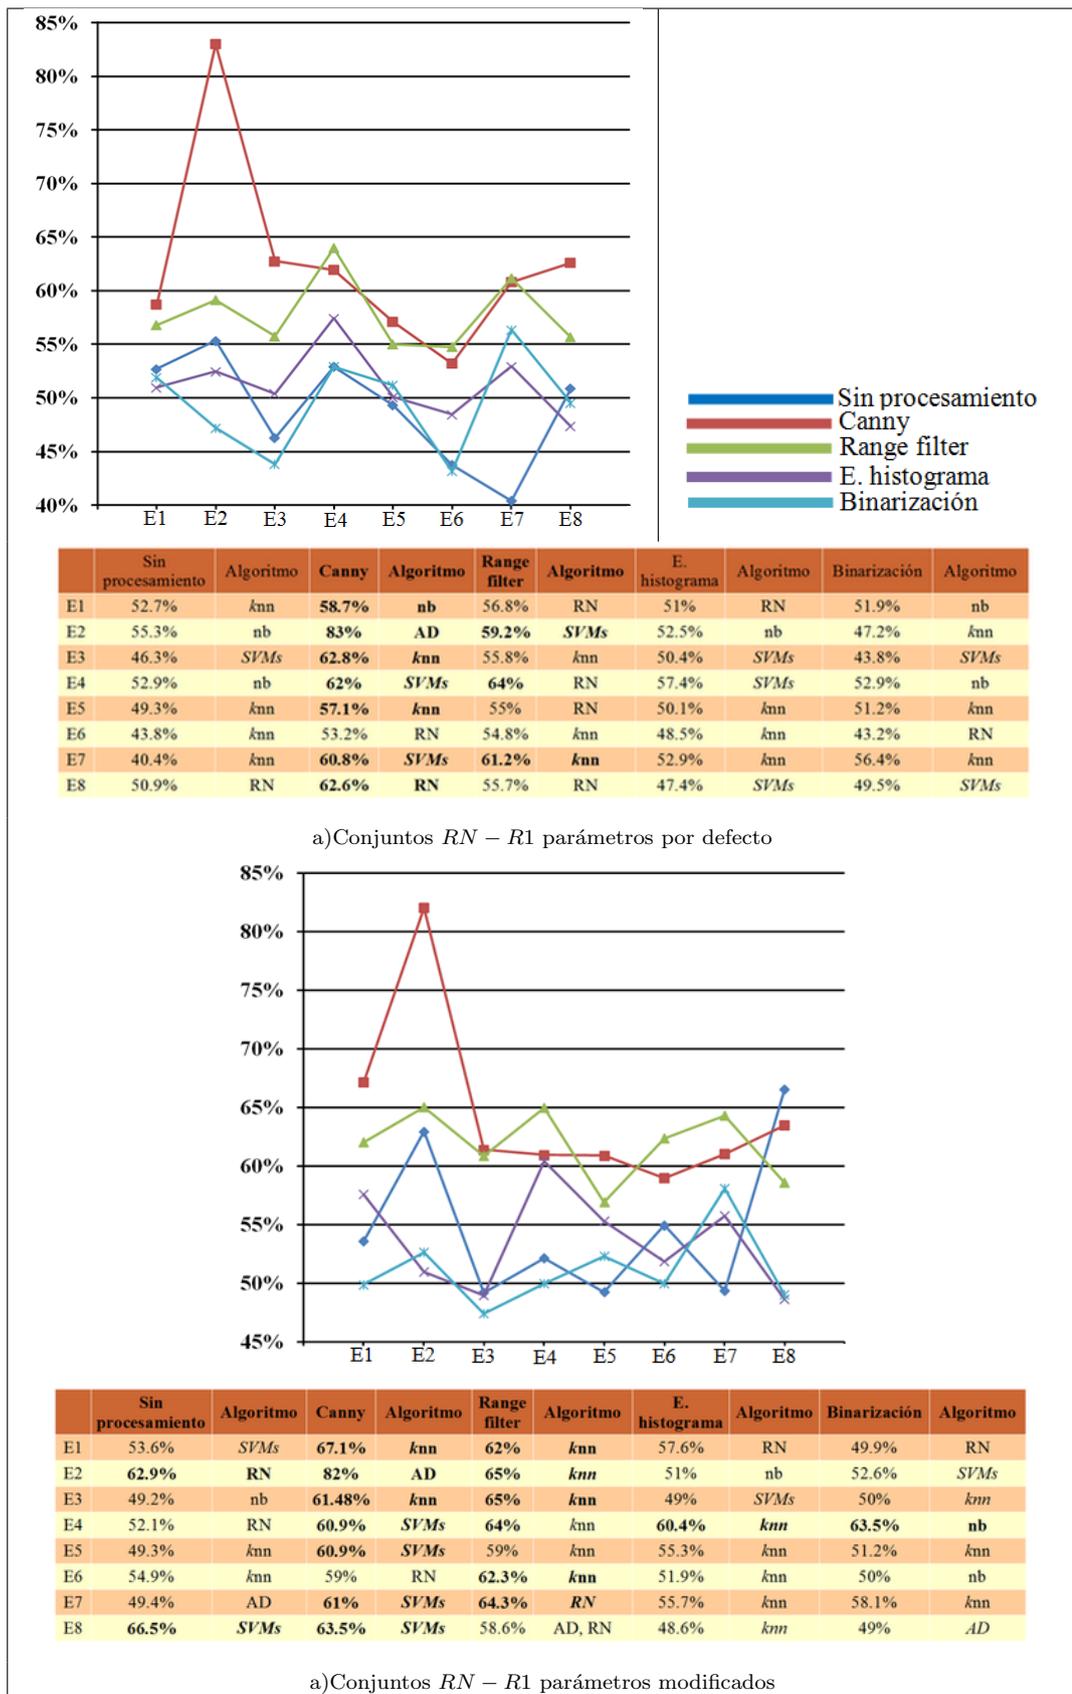


Figura 4.10: Promedio de la métrica *F-measure* del conjunto RN – R1.

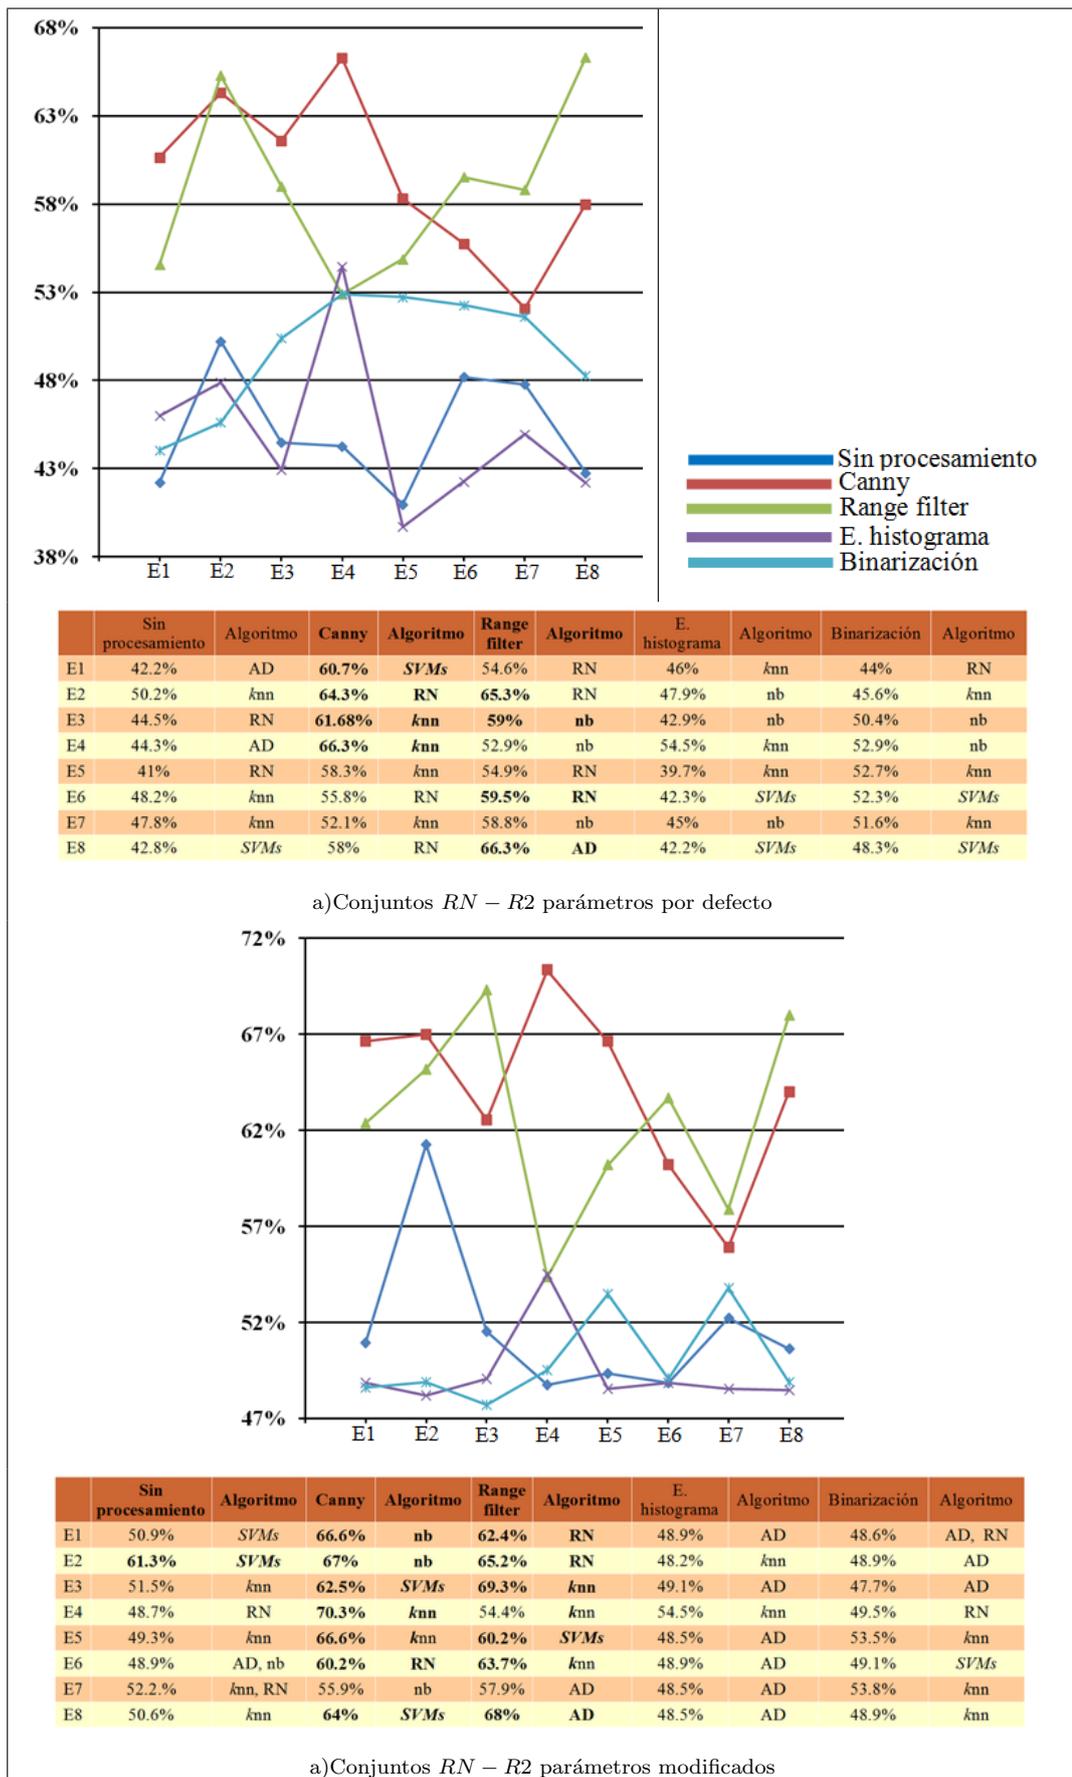


Figura 4.11: Promedio de la métrica F -measure del conjunto RN – R2.

Capítulo 5

Conclusiones

En este trabajo se realizó un método automático para clasificar imágenes con presencia de retinopatía diabética en dos tipos proliferativa y no proliferativa. El cual consistió de 3 etapas: aplicación de técnicas de procesamiento, reducción y caracterización de imágenes y la clasificación de las imágenes en dos tipos. Para la primera etapa se aplicaron las técnicas de procesamiento: detector de bordes Canny, *range-filter*, ecualización del histograma y binarización; en la segunda etapa se usaron dos métodos el análisis de componentes principales y la red neuronal de Hinton, cabe destacar que la red neuronal de Hinton no ha sido usada para este tipo de tareas con imágenes de fondo de ojo, por lo cual es una contribución para su estudio con este tipo de tareas. Y en la clasificación se usaron los siguientes algoritmos de aprendizaje automático: árboles de decisión, k -vecinos más cercanos, naive Bayes, red neuronal y máquinas de vectores de soporte.

Los métodos de *PCA* y la red neuronal de Hinton se compararon en base al menor tiempo de ejecución y características, el mejor fue *PCA*, sin embargo en los resultados de clasificación la red neuronal de Hinton alcanzó porcentajes mayores de 80%. En cuanto a los resultados obtenidos en las reconstrucciones el mejor método fue *PCA*,

al lograr reconstruir todas las imágenes en casi un 100%, mientras que para la red neuronal solo para las técnicas de detector de bordes *Canny* y *range-filter*.

Las técnicas de procesamiento que obtuvieron mejores resultados en la clasificación para *PCA* fueron ecualización del histograma y detector de bordes *Canny*, mientras que para la red neuronal de Hinton fueron *range-filter* y detector de bordes *Canny*, por lo tanto se concluye que la mejor técnica de procesamiento es el detector de bordes *Canny* al obtener mejores resultados en la etapa de clasificación con ambos métodos y el objetivo de aplicar técnicas de procesamiento de imágenes contribuyó a mejorar los resultados en la clasificación para algunos conjuntos, especialmente para el método de la red neuronal de Hinton.

Los algoritmos que tuvieron un mejor desempeño en la tarea de clasificación fueron *k*-vecinos más cercanos, naive Bayes y árboles de decisión. Para *PCA* naive Bayes obtuvo un 80,3% de *precision*, para el conjunto original (*S3*) con todas las resoluciones usando un componente principal; *k*-vecinos más cercanos logro un 75,2% de *accuracy* con el conjunto de 84 imágenes (*S2*) con la resolución de 979×979 pixeles usando entre 5 – 8 componentes principales, ambos algoritmos con las imágenes sin procesamiento. Y para la red neuronal de Hinton, los árboles de decisión obtuvieron un 83,1% de *precision* con el conjunto de 56×56 pixeles (*RN – R1*) usando 755 características, con la técnica de detector de bordes *Canny*; naive Bayes obtuvo un 76,8% con el conjunto de 128×128 pixeles (*RN – R2*) usando 50 características con la técnica de *range-filter*. Sin embargo no se desprecia al resto de los algoritmos debido a que en algunos conjuntos obtuvieron buenos resultados mayores de 70% de *accuracy*, como se observa en las tablas respectivamente.

Trabajo a futuro

Como trabajo futuro se probará el método con un conjunto de imágenes mayor, para tener un mayor conjunto de datos de entrenamiento para mejorar la exactitud en la clasificación de la retinopatía diabética. Así también probar otras técnicas para reducir y caracterizar imágenes como la técnica SIFT (*Scale-invariant feature transform*), histogramas de gradiente y transformada de censo.

Para obtener mejores resultados en cuanto al procesamiento de las imágenes se probarán la técnica segmentación de regiones.

Además se usará aprendizaje automático para datos no balanceados.

Y construir un sistema para clasificar la retinopatía diabética en tiempo real.

AGRADECIMIENTOS

El presente trabajo de investigación fue realizado bajo la supervisión del Dr. Jorge de la Calleja Mora, a quien me gustaría expresar mi agradecimiento, por hacer posible la realización de este estudio, por su paciencia, tiempo y dedicación para que este trabajo se concluyera de manera exitosa y por ser parte fundamental de mi tesis.

A los doctores y maestros que compartieron sus conocimientos para convertirme en una profesionista y por su pasión en la actividad docente, especialmente al Dr. Antonio Benitez y la Dra. Ma. Auxilio Medina.

Agradezco a la Dra. Irma Judith Gutiérrez Herrera, jefa del departamento clínico de oftalmología del Hospital de especialidades IMSS Puebla, por habernos proporcionado el conjunto de imágenes para la experimentación de este trabajo.

Un agradecimiento especial al Dr. Eduardo Torres Porras por todo su apoyo, tiempo y conocimientos y a los doctores Carlos Alberto Coronado Olea y Francisco Tellez.

A mis padres y hermanos, especialmente a mi madre por toda su paciencia y comprensión durante todo este proceso.

A mis amigas, por ser parte de mi vida y por estar en todas las experiencias, por apoyarme y nunca dejarme caer, por sus oraciones y la mejor vibra, no importando el tiempo ni distancia. A Marisol Aguirre, Violeta Valverde, Lucy Valverde, Rocio Cruz, Ruth Yañez, Hna. Esperanza Contreras, Ale Aguirre, Ale Arredondo, Isabel Aguirre, Rosalba Monsalvo, Rosa María, Tere López G., HFIC y a todas aquellas personas que

se han involucrado en mi vida y me han apoyado consiente e inconscientemente. Y a $\lambda\Omega\rho\varepsilon\nu\zeta\Omega-\rho.\zeta$. por ser uno de mis motores que me impulsa a ser mejor cada día, gracias por todo el tiempo, paciencia, comprensión y apoyo incondicional.

Agradezco a Dios, por regalarme la vida y la oportunidad de seguir creciendo espiritualmente y profesionalmente.

Bibliografía

- [1] Foster A. Cataract and vision 2020 -the right to sight initiative. *Br J Ophthalmol*, (85):635–637, 2001.
- [2] Gowda A. and Nasiha A. et al. Exudates detection in retinal images using back propagation neural network. *International Journal of Computer Applications*, 25(3), Julio 2011.
- [3] Karatzoglou A., Meyer D., and Hornik K. Support vector machines in r. *Journal of Statistical Software*, 15(9), Abril 2006.
- [4] Osareh A. and Mirmehdi M. et al. Classification and localization of diabetic-related eye disease. In *Proceedings of the 7th European Conference on Computer Vision-Part IV, ECCV '02*, pages 502–516. Springer-verlag, 2002.
- [5] Sopharak A. and Dailey M. et al. Machine learning approach to automatic exude detection in retinal images from diabetic patients. *Journal of Modern Optics*, 57(2):124–135, Enero 2010.
- [6] Alías A.E. and Borque R.E. et al. Cómo pueden ayudar los analizadores de imagen (hrt, oct y gdx-vcc) en la práctica clínica diaria del oftalmólogo frente al paciente glaucomatoso). *The innovación*, Noviembre 2008.

- [7] Sotelo M. A. et al. Álvarez, S. Vehicle and pedestrian detection in safety applications. In *Proceedings of the WCECS World Congress on Engineering and Computer Science 2009, San Francisco, USA*, 2009.
- [8] C.S. et al Christodoulou C.I. Image retrieval and classification of carotid plaque ultrasound images. *The Open Cardiovascular Imaging Journal*, 2010.
- [9] Instituto Nacional de Estadística y Geografía. Porcentaje de la población con limitación en la actividad según tipo de limitación para cada entidad federativa, 2010. <http://www.inegi.org.mx>.
- [10] PMFARMA (Portal Iberoamericano de Marketing Farmacéutico). Los números de la diabetes en México. 02-Agosto-2007. <http://www.pmfarma.com.mx/noticias/1359-los-numeros-de-la-diabetes-en-mexico.html>.
- [11] Jaude L. et al. Ministerio de salud. guía clínica retinopatía diabética, 2006. http://www.redsalud.gov.cl/archivos/guiasges/Retinopatia_Diabetica_definitiva1_2a.pdf.
- [12] Osareh A. et al. Automatic recognition of exudative maculopathy using fuzzy cmeans clustering and neural networks. In *Medical Image Understanding and Analysis*, volume 1, pages 49–52. BMVA Press, 2001.
- [13] Prado-Serrano A et al. Prevalencia de retinopatía diabética en población mexicana. *Rev Mex Oftalmol*, pages 261–266, 2009.
- [14] Ejarque P. et al. Farrús, M. Histogram equalization in svm multimodal person verification. In *Proceedings of the IEEE International Conference on Biometrics, Seoul, Korea*, number 4642, pages 819–827. LNCS, 2007.
- [15] Hinton G. Página de Geoffrey E. Hinton. <http://www.cs.toronto.edu/~hinton/>.

- [16] Manzanaro G. Fotografía de fondo de ojo con filtros. Boletín de la Sociedad Oftalmológica de Madrid, 2004. <http://www.oftalmo.com/som/revista-2004/m2004-07.htm>.
- [17] López L.G. and Gástelum G.J. Prevalencia de glaucoma primario en la coordinación universitaria del Hospital Civil de Culiacán en el periodo 2003-2005. *Bol Med UAS*, 2(12), Febrero-Abril 2006.
- [18] Tewari H., Verma L., and Venkatesh P. *Fluorescein Angiography-A user's Manual*. 2008.
- [19] Huang J. Huang M., Chen H. Glaucoma detection using adaptive neuro-fuzzy inference system. *ScienceDirect, Expert Systems with Applications*, (32):458–468, 2007.
- [20] Laan J. and Treur J. Agent model for computational analysis of mirroring dysfunctioning in autism spectrum disorders. In *Modern Approaches in Applied Intelligence*, number 24, pages 306–316. Springer, 2011.
- [21] Zheng J. and Fuentes O. et al. Mammogram compression using super-resolution. In *Proceedings of digital Mammography/IWDM*, pages 46–53, 2010.
- [22] Burges Christopher J.C. A tutorial on support vector machines for recognition. *Data mining and knowledge Discovery*, 2:121–167, 1998.
- [23] Baker J. Jesneck J., Lo J. Breast mass lesions: Computeraided diagnosis models with mammographic and sonographic. *Radiology*, 244(2):390–398, 2007.
- [24] Kancherla K. and Mukkamala S. Lung cancer detection using labeled sputum sample: Multi spectrum approach. In *Modern Approaches in Applied Intelligence*, number 24, pages 446–458. Springer, 2011.

- [25] Englmeier K-H and Hildebrand C. et al. Early detection of diabetes retinopathy by new algorithms for automatic recognition of vascular changes. *European Journal of Medical Research*, pages 473–478, Octubre 2004.
- [26] Christy T. et al Kuncheva L. Multi-modal biometric emotion recognition using classifier ensembles. In *Modern Approaches in Applied Intelligence*, number 24, pages 317–326. Springer, 2011.
- [27] Goldbaum M. Unsupervised learning with independent component analysis can identify patterns of glaucomatous visual field defects. *Trans Am Ophthalmol Soc*, pages 270–280, 2005.
- [28] Turk M. and Pentland A. Eigengaces for recognition. *Journal of Cognitive Neuroscience*, 3(1):71–86, 1991.
- [29] Sánchez M. Martínez A. Predictive value of colour doppler imaging a prospective study of visual field progression in primary open-angle glaucoma. *Acta Ophthalmol Scand*, (83):716–722, 2005.
- [30] Babayán M.J. Diabetes y glaucoma. *RevMexOftalmol*, 5(79):235–241, Septiembre 2005.
- [31] Bokde Al. et al Mourão-Miranda J. Classifying brain states and determining the discriminating activation patterns: Support vector machine on functional mri data. *Neuroimage*, 4(28):980–995, Diciembre 2005.
- [32] Silberman N. and Ahlrich K. et al. Case for automated detection of diabetic retinopathy. In *AAAI Spring Symposium on AI for Development*, 2010.
- [33] Hazanchuk A. Neoh, H.S. Adaptive edge detection for real-time video processing using fpgas. In *GSPx 2004 Conference 2004*, volume 3, 2004.

- [34] Ginneken B. et al Niemeijer M. Automatic detection and differentiation of drusen, exudates, and cotton-wool spots in digital color fundus photographs for diabetic retinopathy diagnosis. *Investigative Ophthalmology & Visual Science*, 48(5), Mayo 2007.
- [35] Textbook of ophthalmology. *Advances in ophthalmology*. New Delhi 110 002, India, 5 edition, 2008.
- [36] Sample P. and Goldbaum M. et al. Using machine learning classifiers to identify glaucomatous change earlier in standar visual fields. *Investigative Ophthalmology & Visual Science*, 43(8), Agosto 2002.
- [37] IMAGERET PROJECT. Standar diabetic retinopathy database, 2007. <http://www2.it.lut.fi/project/imageret/diaretdb1>.
- [38] Bock R. and Meier J. et al. Classifying glaucoma with image-based features from fundus photographs. In *Proceedings of DAGM Conference on Pattern recognition*. Springer, 2007.
- [39] Gonzalez R. and Woods R. *Digital Image Processing*. New Jersey, 2008.
- [40] Bonafarte S., García Ch., and Davis M. *Retinopatía Diabética*. España, S.A., 2a. edition, 2006.
- [41] Joshi S. and Simha V. et al. Classification of neurodegenerative disorders based on major risk factors employing machine learning techniques. In *IACSIT International Journal of Engineering and Technology*, Agosto 2010.
- [42] Kavitha S. and Duraiswamy K. Automatic detection of hard and soft exudates in fundus images using color histogram thresholding. *European Journal of Science Research*, 48(3):493–504, 2011.

- [43] Reddy S. and Kurli M. et al. Pet/ct imaging: detection of choroidal melanoma. *Br J Ophthalmol*, 10(89):1265–1269, 2005.
- [44] Russell S. and Norving P. *Artificial Intelligence, a modern approach*. New Jersey, 2010.
- [45] Salud180.com. Se elevan casos de ceguera por diabetes. 19-11Noviembre-2010. <http://www.salud180.com/salud-dia-a-dia/habitos-sanos/cuerpo/se-elevan-casos-de-ceguera-por-diabetes>.
- [46] Saludalia. Fondo de ojo. http://www.saludalia.com/docs/Salud/web_saludalia/temas_de_salud/doc/ofthalmologia/doc/doc_fondo_ojo.htm.
- [47] Cross SS. Sharkey AJC., Sharkey NE. Adapting an ensemble approach for the diagnosis of breast cancer. In *Proceedings of the International Conference on Artificial Neuronal Networks*, pages 281–286, 1998.
- [48] El siglo de Torreon. retinopatía diabética es el principal causante de ceguera. 23-Septiembre-2007. <http://www.elsiglodetorreon.com.mx/noticia/299282.retinopatia-diabetica-es-el-principal-padecim.html>.
- [49] Uyyanonvara B. et al Sopharak A. Comparative analysis of automatic exudate detection algorithms. In *Proceeding of the World Congress on Engineering 2010*, volume 1, 2010.
- [50] Mitchell T. *Machine Learning*. United States, 1997.
- [51] UNiversia. La ceguera es la segunda causa de discapacidad en México:inegi. 29-04-2005. <http://noticias.universia.net.mx/ciencia-nn-tt/noticia/2005/04/29/97078/ceguera-es-segunda-causa-discapacidad-mexico-inegi.pdf>.

- [52] Erraguntla V. and Mackeen LD. et al. Assessment if change of optic nerve head cupping in pediatric glaucoma using the retcam 120. *J AAPOS*, 6(10):528–533, 2006.
- [53] Azad R. Venkatesh P., Garg S. *Retinal Imaging*. New Delhi 110 002, India, 2008.
- [54] Informativo Web. Retinopatía diabética, primera causa de ceguera en México.
- [55] Fan Y., Shen D., and Davatzikos Ch. Classification of structural images via high-dimensional image warping, robust feature extraction, and svm. In *Medical Image Computing and Computer-Assisted Intervention MICCAI*, pages 1–8. Springer-Verlag Berlin Heidelberg, 2005.
- [56] Zhou Z. and Jiang Y. et al. Lung cancer cell identification based on artificial neural networks ensembles. *Artificial Intelligence in Medicine*, (24):25–36, 2002.
- [57] Chan K. Zangwill L. and Bowd Ch. et al. Heidelberg retina tomograph measurements of the optic disc and parapapillary retina for detecting glaucoma analyzed by machine learning classifiers. *Ophthalmol Vis Sci*, 9(45):3144–3151, 2004.