



UNIVERSIDAD NACIONAL DEL ALTIPLANO

ESCUELA DE POSGRADO

MAESTRÍA EN INFORMÁTICA



TESIS

SEGMENTACIÓN AUTOMÁTICA NO SUPERVISADA DE IMÁGENES
MEDIANTE AGRUPAMIENTO ESPECTRAL

PRESENTADA POR:

HENRY NILTON TITO VALDEZ

PARA OPTAR EL GRADO ACADÉMICO DE:

MAGISTER SCIENTIAE EN INFORMÁTICA

CON MENCIÓN EN INGENIERÍA DE SOFTWARE

PUNO, PERÚ

2020

Reporte de similitud

NOMBRE DEL TRABAJO

SEGMENTACIÓN AUTOMÁTICA NO SUPERVISADA DE IMÁGENES MEDIANTE AGUPAMIENTO ESPECTRAL

AUTOR

HENRY NILTON TITO VALDEZ

RECuento de palabras

18674 Words

RECuento de caracteres

104570 Characters

RECuento de páginas

86 Pages

Tamaño del archivo

1.8MB

FECHA DE ENTREGA

Aug 14, 2024 2:59 PM GMT-5

FECHA DEL INFORME

Aug 14, 2024 3:00 PM GMT-5

● **17% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 16% Base de datos de Internet
- Base de datos de Crossref
- 7% Base de datos de trabajos entregados
- 2% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● **Excluir del Reporte de Similitud**

- Material bibliográfico
- Material citado
- Material citado
- Coincidencia baja (menos de 12 palabras)

Henry Nilton Tito Valdez
Ing. Estadístico e Informático
DOCENTE



Resumen



UNIVERSIDAD NACIONAL DEL ALTIPLANO

ESCUELA DE POSGRADO

MAESTRÍA EN INFORMÁTICA

TESIS

SEGMENTACIÓN AUTOMÁTICA NO SUPERVISADA DE IMÁGENES MEDIANTE AGRUPAMIENTO ESPECTRAL

PRESENTADA POR:

HENRY NILTON TITO VALDEZ

PARA OPTAR EL GRADO ACADÉMICO DE:

MAGISTER SCIENTIAE EN INFORMÁTICA

CON MENCIÓN EN INGENIERÍA DE SOFTWARE

APROBADA POR EL JURADO SIGUIENTE:

PRESIDENTE

.....
D.Sc. PERCY HUATA PANCA

PRIMER MIEMBRO

.....
M.Sc. ERNESTO NAYER TUMI FIGUEROA

SEGUNDO MIEMBRO

.....
Dr. FREDY ERICK VILLASANTE SARAVIA

ASESOR DE TESIS

.....
Dr. RENZO APAZA CUTIPA

Puno, 16 de enero del 2020.

ÁREA: Informática.

TEMA: Agrupamiento Espectral.

LÍNEA: Simulación.



DEDICATORIA

“Con mucho amor para mi querida familia, quien con esfuerzo, dedicación y apoyo constante me ayudo durante mi formación profesional.

A Dios que guio mis pasos y alumbro mi camino. Y siempre me dijo esfuérsate y se valiente ¡Oh Señor Jesús!”



AGRADECIMIENTOS

Quiero expresar mi agradecimiento al personal universitario por su colaboración durante la elaboración de mi tesis.

Agradezco sinceramente a los docentes de la Escuela de Posgrado de la Maestría en Informática de la Universidad Nacional del Altiplano por compartir su sabiduría, los cuales han sido fundamentales para mi desarrollo profesional.

Agradezco la guía y el apoyo brindados por mi asesor a lo largo de la ejecución de este estudio.



ÍNDICE GENERAL

	Pág.
DEDICATORIA	i
AGRADECIMIENTOS	ii
ÍNDICE GENERAL	iii
ÍNDICE DE TABLAS	v
ÍNDICE DE FIGURAS	vi
ÍNDICE DE ANEXOS	vii
RESUMEN	viii
ABSTRACT	ix
INTRODUCCIÓN	1

CAPÍTULO I

REVISION DE LITERATURA

1.1. Marco teórico	3
1.1.1. Algoritmos de segmentación	3
1.1.2. Métodos de agrupamiento	5
1.1.3. Métodos basados en el histograma	8
1.2. Antecedentes	17

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1. Identificación del problema	23
2.2. Enunciados del problema	24
2.3. Justificación	24
2.4. Objetivos	25
2.4.1. Objetivo general	25
2.4.2. Objetivos específicos	25
2.5. Hipótesis	25
2.5.1. Hipótesis general	25
2.5.2. Hipótesis específicas	26

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. Lugar de estudio	27
3.2. Población	28



3.3. Muestra	28
3.4. Método de investigación	29
3.5. Descripción detallada de métodos por objetivos específicos	30
CAPÍTULO IV	
RESULTADOS Y DISCUSIÓN	
4.1. Objetivo general	35
4.1.1. Imágenes de prueba	35
4.1.2. Análisis de varianza	38
4.1.3. Prueba post ANVA DMS	39
CONCLUSIONES	53
RECOMENDACIONES	54
BIBLIOGRAFÍA	56
ANEXOS	62



ÍNDICE DE TABLAS

	Pág.
1. Especificaciones de aplicación de la métrica	34
2. Datos originales de evaluación basada en la región y peso de los bordes	36
3. Evaluación basada en la región y peso de los bordes	37
4. Análisis de varianza para los parámetros porcentajes de error debido al ajuste del parámetro α	38
5. Prueba post ANVA DMS	39
6. Resultados de la efectividad del método de segmentación propuesto mediante la evaluación del Puntaje F1, Coeficiente Dice e Índice Jaccard	42
7. Efectividad promedio del método de segmentación	43



ÍNDICE DE FIGURAS

	Pág.
1. Puntos de la imagen	6
2. K clústeres a partir de los puntos anteriores	7
3. Centro de gravedad de cada uno de los grupos K	7
4. Se repiten hasta que alcance la convergencia	8
5. k clúster a partir de los puntos anteriores	9
6. K Conjunto de imágenes sintéticas generadas agregando ruido gaussiano con valores de desviación estándar (a) 1, (b) 2 y (c) 4	35
7. Gráfico de medias de los promedios de los errores porcentuales del algoritmo de segmentación	40
8. Efectividad según las métricas Puntaje F1, Coeficiente Dice y el Índice de Jaccard	43
9. Diagrama del software para la segmentación de imágenes	45
10. Resultados de la segmentación utilizando la implementación realizada	50
11. Una efectividad promedio mayor al 90%	51
12. Pantalla de carga de Intel® MKL	69
13. Pantalla de activación del producto	70
14. Programa de mejora de Intel®	71
15. Carpeta de instalación	71
16. Componentes del paquete	72
17. Recuento de las características seleccionadas para instalar	72
18. Finalizar la instalación	73
19. Área de trabajo de la aplicación	74
20. Parámetros de configuración	75



ÍNDICE DE ANEXOS

	Pág.
1. Matriz del problema de investigación	62
2. Clustering espectral	63
3. Manual del usuario	67

RESUMEN

La segmentación suele presentar el paso inicial, y al mismo tiempo, el más crucial en un sistema de evaluación de imágenes porque sus resultados influirán en los pasos posteriores. La intención de este estudio es analizar la efectividad de la segmentación, automática no supervisada de imágenes mediante agrupamiento espectral. El algoritmo guio este trabajo para desarrollar un método de segmentación de imágenes que resuelve dos problemas principales, primero, reducir los tiempos de ejecución y segundo, lograr la segmentación en regiones coherentes en una determinada imagen, de manera que creamos que se han logrado satisfactoriamente los objetivos planteados. Se realizó la implementación de una aplicación informática que realiza de forma automática la segmentación de imágenes mediante agrupamiento espectral, esta se realizó en lenguaje de programación R, la implementación de los siguientes módulos, adquisición preprocesamiento (Smoothing y Redimensionamiento), vector, cálculo de la matriz de conversión similaridad, de matriz imagen, matriz a Laplaciana Normalizada/unnormalizada, Proyectar en la imagen original, los desenlaces mostraron que procedimiento de segmentación propuesto tiene una efectividad promedio de 91.5% mediante el puntaje F1, 90.5% mediante el Coeficiente Dice y una efectividad del 90.7% según el nómina de Jaccard. Es decir que el enfoque propuesto tiene una efectividad promedio mayor al 90%.

Palabras clave: Agrupamiento espectral, métrica de precisión, pixeles, segmentación automática y segmentación de imágenes.

ABSTRACT

Segmentering is dikwels die eerste en belangrikste stap in 'n beeldontledingstelsel omdat die resultate daarvan die daaropvolgende stappe sal beïnvloed. Die hoofdoel van hierdie navorsingswerk is om die doeltreffendheid van Outomatiese beeldsegmentering sonder toesig deur spektrale groepering te bepaal. Ons kan sien hoe die algoritme hierdie werk gelei het om 'n beeldsegmenteringsmetode te ontwikkel wat twee hoofprobleme oplos, eerstens om uitvoeringstye te verminder en tweedens om segmentering in samehangende streke in 'n gegewe beeld te bewerkstellig, sodat ons glo dat die voorgestelde bevredigende bereik is. Doelwitte, kan ons sien hoe die ontwikkelde algoritme het aansienlik verkort die reaksie tyd in vergelyking met die klassieke algoritme (SC), die hoofrede is die bekendstelling van superpixel tegnologie in die vorige segmentering stadium, wat die reaksie tyd verkort SFSC runtime. Die implementering van 'n rekenaartoeëpassing wat outomaties die segmentering van beelde deur middel van spektrale groepering uitvoer, is uitgevoer, dit is uitgevoer in R programmeertaal, die implementering van die volgende modules Verkryging Voorverwerking (Smoothing en Verander grootte), Vektor, Berekening van die matriks Ooreenstemming Omskakeling, Beeldmatriks, Genormaliseerde/ongenormaliseerde Laplacian-matriks, Groepeer beelde om eiewaardes te segmenteer en K-middele, Projek op die oorspronklike beeld, die resultate het getoon dat die voorgestelde segmenteringsmetode 'n gemiddelde doeltreffendheid van 91.5% het deur die F1-telling, 90.5% deur die Dobbelsteenkoëffisiënt en 'n doeltreffendheid van 90,7% volgens die Jaccard-indeks. Dit beteken dat die voorgestelde metode 'n gemiddelde doeltreffendheid van meer as 90% het.

Keywords: Automatic segmentation, image segmentation, pixels, precision metric and spectral clustering.

INTRODUCCIÓN

La visión computacional, una disciplina muy empleada en la inteligencia artificial contemporánea, presenta una amplia variedad de usos fundamentales, incluyendo el control de calidad y el análisis de imágenes, así como la supervisión de diversos procesos. La segmentación de imágenes, uno de los pilares esenciales de la visión por computadora, juega un papel crucial, ya que de su correcta ejecución depende una interpretación precisa de la realidad. La tarea de segmentación implica dividir la imagen en regiones no superpuestas que compartan características homogéneas, como la intensidad del color, la textura, entre otras (Wang, 2010). A pesar de su implementación sencilla y la eficacia demostrada a lo largo de décadas, los enfoques tradicionales de agrupamiento espectral han sido ampliamente utilizados en la segmentación de imágenes, la mayoría de estos algoritmos tienen que lidiar con un elevado costo computacional y tiempo de procesamiento (Ynag, 2016).

El incremento en el tiempo de procesamiento y el aumento en el gasto computacional se asocia principalmente con la generación de la matriz de similitud, que abarca todas las relaciones potenciales entre los pares de puntos que constituyen la imagen, lo que resulta en un cálculo de datos complejo y un consumo excesivo de memoria (Zhao, 2010).

En la actualidad, es frecuente trabajar con imágenes de alta definición (HD), que generalmente tienen un tamaño de 1920x1080 píxeles. Además, las imágenes con resoluciones aún mayores están ganando popularidad. Este considerable aumento en la cantidad de datos para procesar amplifica significativamente las limitaciones de los algoritmos de agrupamiento espectral clásicos (Wang, 2012).

La mayoría de los algoritmos de agrupamiento espectral utilizan la función gaussiana como medida de similitud (Xu, 2013), sin embargo, esta no puede reflejar plenamente la compleja distribución espacial del conjunto de datos, y si es indeseable cuando los grupos de datos se desarrollan sobre una estructura compleja.

Li (2016) en la construcción de la matriz de similitud, surge el desafío de encontrar una medida más robusta de similitud de pares de datos, contrarrestar la medida generada por su función de núcleo gaussiano. Para abordar este problema, se propone un enfoque no supervisado denominado AFSSC (Axiomatic Fuzzy Set-based Spectral Clustering), el cual capitaliza las características discriminantes. Este método tiene la capacidad de



capturar y combinar información de similitud distribuida en subespacios, lo que permite revelar con mayor precisión la distribución de los datos (Li, 2016). De manera destacada, este enfoque exhibió un desempeño satisfactorio en conjuntos de datos que incluían numerosas características redundantes y/o componentes con ruido.

El informe consta de cuatro (04) secciones principales. En el Capítulo I, se realiza una inspección de la literatura que abarca el contexto teórico y los referentes históricos. El Capítulo II se dedica al planteamiento del problema, explorando la teoría existente en relación con las variables de investigación. Este capítulo se compone de dos áreas temáticas principales. En primer término, se expone la teoría relacionada con las aplicaciones web, las metodologías de desarrollo de software, los patrones de diseño y las técnicas de programación AJAX. El Capítulo III introduce los materiales y métodos de investigación, detallando el tipo, nivel y diseño de la investigación utilizados. Finalmente, el Capítulo IV examina los resultados y su consiguiente discusión.

CAPÍTULO I

REVISION DE LITERATURA

1.1. Marco teórico

1.1.1. Algoritmos de segmentación

Dentro del campo de la visión artificial, la segmentación se define como el procedimiento para partir una imagen digital en múltiples segmentos, conformadas por conjuntos de píxeles o partes. El objetivo fundamental de la segmentación es simplificar y/o transformar la representación de una imagen hacia una forma más relevante y sencilla de analizar. Este método se utiliza no solo para la ubicación de objetos como la identificación de sus límites al interior de la imagen. Más precisamente, la segmentación de la imagen es el proceso de asignación de una etiqueta a cada píxel de la imagen de forma que los píxeles que compartan la misma etiqueta también tendrán ciertas características visuales similares (Dass, 2016).

Transformar una imagen digital implica la acción de dividirla en áreas distintas e individualizadas. Es decir, se trata de distinguir los diversos objetos presentes y su posición con respecto al fondo, que puede tener diferentes niveles de complejidad en la imagen. Al término de la fase de transformación, es esencial tener un conocimiento detallado de los objetos presentes para así extraer las características particulares de cada uno de ellos. Además, cada píxel de la imagen tiene que tener una etiqueta que los defina, de forma que simplemente por agrupación de puntos con la misma etiqueta y conectados espacialmente, se pueda determinar la lista de objetos, estos objetos son realmente zonas o regiones individualizadas dentro de la imagen, ya que un objeto, en el sentido estricto de la palabra, puede estar repartido en varias regiones diferentes (Gonzales, 2006).

La segmentación implica separar una imagen en conjuntos de píxeles que exhiben homogeneidad con respecto a algún criterio específico. Los diferentes grupos no deben cruzarse entre sí y los grupos adyacentes deben ser heterogéneos. Los grupos se llaman segmentos. El criterio de homogeneidad utilizado para segmentar se basa solo en la similitud de las intensidades de píxeles. Para imágenes que contienen grandes cantidades de ruido o estructura fina, este criterio puede ser insuficiente para una segmentación exitosa. En esos casos, se requiere cierta información sobre la relación espacial entre píxeles. En particular, se aprovecha la suposición de que se espera que los píxeles que pertenecen al mismo segmento estén conectados espacialmente (Seemann, 2002).

La segmentación consiste en dividir la imagen en áreas significativas, generalmente para identificar objetos o regiones de interés ("primer plano") en contraste con el resto ("fondo"). En situaciones más sencillas, estas dos clasificaciones (primer plano y fondo) son las únicas presentes, dando lugar a una imagen segmentada de tipo binario. El atributo principal utilizado para definir estas áreas suele ser el nivel de gris o la luminosidad de la imagen, aunque también otras características, como el color o la textura, pueden ser tenidas en cuenta en casos más simples. La segmentación generalmente constituye la fase inicial en los sistemas de reconocimiento de patrones. Una vez que los objetos de interés se encuentran aislados del resto de la imagen, se pueden llevar a cabo mediciones de caracterización mediante la extracción de características que se utilizan para clasificar los objetos en grupos o clases específicas. Hay diversos enfoques de segmentación, clasificables según las características y técnicas empleadas, que incluyen valores de gris (luminosidad), textura y magnitudes de gradiente (Dougherty, 2009).

1.1.2. Métodos de agrupamiento

El algoritmo K-means se utiliza para dividir una imagen en K clústeres. La metodología fundamental del algoritmo implica:

1. Elegir K núcleo de clústeres, ya sea de manera aleatoria o mediante algún método heurístico.
2. Designar cada píxel de la imagen el clúster donde reduce al mínimo la variabilidad. entre el píxel y el centro del clúster.
3. Actualizar los núcleos de los clústeres mediante el cálculo del promedio de todos los píxeles pertenecientes a cada clúster.
4. Iterar con pasos 2 y 3 de manera iterativa para alcanzar la convergencia, es decir, hasta que los píxeles ya no experimenten cambios en su asignación de clúster.

En este contexto, la varianza se define como la discrepancia absoluta entre un píxel y el centro del clúster. Esta disparidad se basa comúnmente en características como el color, la intensidad, la textura y la ubicación del píxel, o en una combinación ponderada de estos factores donde el valor de K puede ser seleccionado manualmente, de forma aleatoria o a través de algún método heurístico (Wang, 2010). La calidad de la solución depende de la serie inicial de clústeres y del valor de K (Arbeláez, 2011). En el campo de la estadística y el aprendizaje automático, el algoritmo de k-medias es una técnica de agrupamiento utilizada para dividir objetos en k grupos, donde k es menor que n (el número total de objetos). Se asemeja al algoritmo de maximización de expectativas para mezclas gaussianas, ya que ambos buscan identificar los centros de agrupación natural de los datos. Este modelo presupone que los atributos del objeto corresponden a elementos en un espacio vectorial. El propósito fundamental es minimizar la varianza total entre los clústeres, o, dicho de otra manera, la función de error al cuadrado. Por esta razón, el algoritmo de k-medias fue concebido por primera vez en 1956 (Achanta, 2011). La variante más común del algoritmo de k-medias utiliza una heurística de refinamiento conocida como el algoritmo de Lloyd. Este método inicia dividiendo los puntos de entrada en k conjuntos iniciales, ya sea de forma aleatoria o utilizando ciertos datos heurísticos. Posteriormente, se calcula el punto medio o centro de gravedad de cada conjunto, y se genera una nueva partición asignando cada punto al centro de gravedad más

cercano. Después, se recalculan los centros de gravedad para los nuevos clústeres, y el algoritmo se repite alternando la aplicación de estos dos pasos hasta alcanzar la convergencia. Esta última se alcanza cuando los puntos dejan de cambiar de clúster o los centros de gravedad dejan de modificarse. Con frecuencia, los términos "algoritmo de Lloyd" y "algoritmo de las K-medias" A menudo se emplean como sinónimos, pero en realidad, el algoritmo de Lloyd es una heurística específicamente diseñada para abordar el problema de las K-medias. En algunas configuraciones de puntos de inicio y baricentros, el algoritmo de Lloyd podría converger hacia una solución incorrecta. A pesar de la existencia de otras variantes, el algoritmo de Lloyd es el más ampliamente utilizado gracias a su rápida convergencia. En términos de rendimiento, el algoritmo no garantiza la obtención de un óptimo global. La calidad de la solución final depende en gran medida del conjunto inicial de clústeres y, en la práctica, puede ser significativamente menos efectiva que el óptimo global. Debido a la notable velocidad del algoritmo, es común aplicarlo múltiples veces y elegir las agrupaciones más óptimas. Sin embargo, una limitación del algoritmo de k-medias es que el número de clústeres, k , constituye un parámetro crucial de entrada. Una selección inapropiada de k puede conducir a resultados menos precisos. Además, el algoritmo asume que la varianza es una medida adecuada de la dispersión del clúster (García, 2022).




Figura 1. Puntos de la imagen

Fuente: (Díaz y Cañas, 2016).




Figura 2. K clústeres a partir de los puntos anteriores

Fuente: (Díaz y Cañas, 2016).




Figura 3. Centro de gravedad de cada uno de los grupos K

Fuente: Díaz y Cañas (2016).

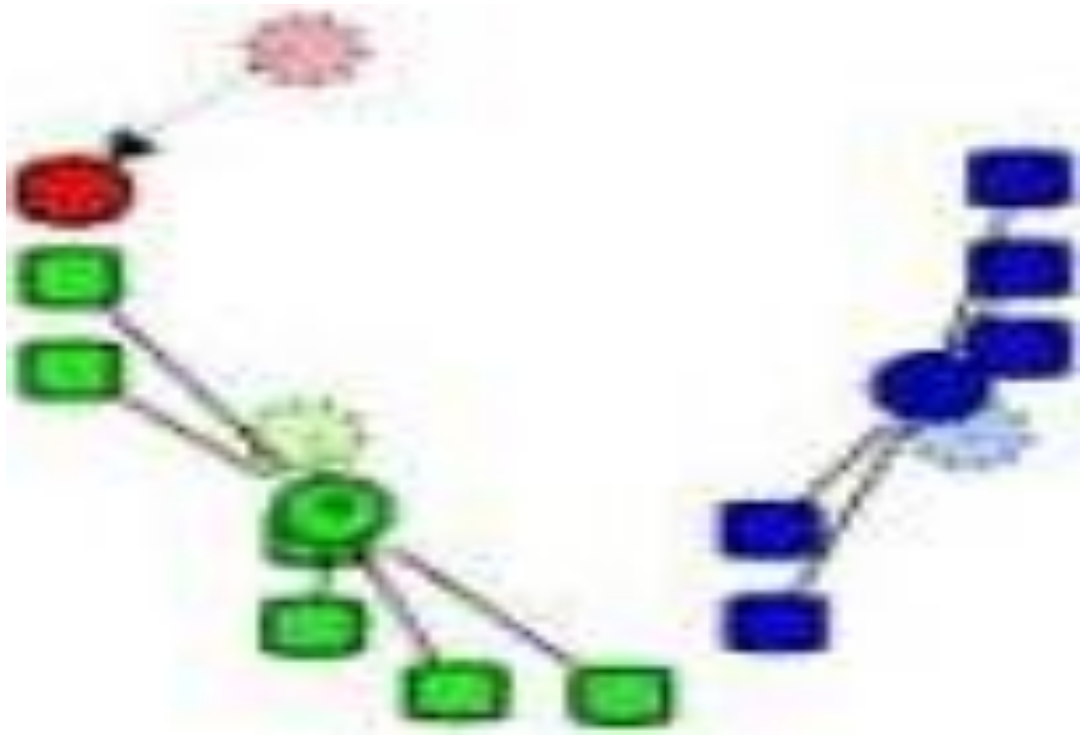


Figura 4. Se repiten hasta que alcance la convergencia

Fuente: Díaz y Cañas (2016).

1.1.3. Métodos basados en el histograma

Los métodos basados en el histograma son altamente eficientes en comparación con otros enfoques de segmentación de imágenes, dado que generalmente solo necesitan una única iteración a través de los píxeles. En esta metodología, se calcula un histograma a partir de todos los píxeles de la imagen, y los máximos y mínimos en el histograma se utilizan para identificar las regiones, considerando tanto el color como la intensidad. Una fortaleza de esta técnica implica aplicar de manera recursiva el método de búsqueda de histograma a los clústeres de la imagen con el objetivo de subdividirlos en grupos más pequeños. Este proceso se repercute con todas las agrupaciones, cada vez más pequeñas, hasta que no sea posible formar más subdivisiones (Castillo, 2016). Una desventaja del método de búsqueda de histograma es que puede ser difícil de identificar los picos y valles importantes en la imagen (Castillo, 2016).




Figura 5. k clúster a partir de los puntos anteriores

Fuente: (Seemann, 2002).

El histograma de una imagen se representa como un gráfico de barras en el que se colocan horizontalmente los niveles de cuantización, y la altura de cada barra es proporcional al número de píxeles en cada nivel de cuantización (Ponce, 2012). Estos histogramas son comúnmente generados para imágenes en escala de grises, con 256 niveles de intensidad. En el caso de imágenes a color, se crea un histograma para cada una de las componentes RGB de la imagen. Además, es una práctica habitual normalizar el histograma en un rango de 0 a 1 para evitar dependencias en el número de píxeles o niveles.

- **Ajuste de contraste**

El contraste se caracteriza por la marcada diferencia de intensidades, al utilizar una función de transferencia del histograma que realce los niveles oscuros y disminuya los niveles claros, podemos mejorar el contraste de la imagen. Por otro lado, al realizar la operación opuesta, disminuirémos el contraste.

- **Detección de bordes**

La identificación de bordes es un área extensamente estudiada en el procesamiento de imágenes. Los límites de las regiones y los bordes están inherentemente relacionados, ya que con frecuencia se produce un cambio abrupto en la intensidad

en los límites de las regiones. Las técnicas de detección de bordes pueden ser utilizadas como un método adicional para llevar a cabo la segmentación de la imagen. No obstante, es importante señalar que los bordes identificados mediante la detección de bordes a veces pueden encontrarse desconectados. Para segmentar un objeto a partir de una imagen, sin embargo, es necesario que los bordes formen figuras cerradas (Shi, 2000).

El proceso de identificar y resaltar cambios abruptos en una imagen se conoce como detección de bordes. Estos cambios bruscos representan discontinuidades inmediatas en la concentración de píxeles, al señalar los límites de los objetos en una escena, los métodos tradicionales de detección de bordes implican la convolución de la imagen mediante un operador diseñado para ser sensible a gradientes pronunciados. Estos operadores generan valores cercanos a cero en regiones uniformes de la imagen. Existen diversas técnicas de detección de bordes, cada una diseñada para ser perceptiva a tipos específicos de extremos. Las variables relacionadas con la selección de un operador de detección de bordes consisten en la orientación del borde, la estructura del borde y el entorno de ruido (Radha, 2011).

- **Métodos de crecimiento de regiones**

El método inicial de crecimiento de regiones fue el método de crecimiento de regiones a partir de semillas, en este enfoque, se suministra un conjunto de semillas junto con la imagen como entrada. Estos sirven para identificar los objetos que deben ser segmentados. Las regiones se desarrollan de manera iterativa al comparar todos los píxeles vecinos no asignados a ninguna región. La similitud se mide utilizando la diferencia entre el valor de intensidad de un píxel y la media de la región. Cada píxel se asigna a la región con la que su diferencia con la media es menor, de esta forma todos los píxeles se asignan a sus respectivas regiones (Oh, 2017).

Este procedimiento se realiza de manera iterativa hasta que cada píxel se asigna a una región específica. Sin embargo, es importante destacar que el método de crecimiento de regiones a partir de semillas demanda la introducción de semillas adicionales, y los resultados de la segmentación están fuertemente influenciados por la elección de estas semillas. La presencia de ruido en la imagen puede conducir a una colocación incorrecta de las semillas, lo que afecta la precisión y calidad general de la segmentación. El método de crecimiento de regiones sin semillas es un

algoritmo modificado que no requiere semillas explícitas (Meunkaewjinda, 2008), (Prayoth, 2008). Inicia con una única región A_1 , donde el píxel seleccionado en este punto no influye de manera significativa en la segmentación final. En cada iteración se considera los píxeles vecinos de la misma manera que con el algoritmo anterior (Bashish, 2010) se diferencia del algoritmo el método de crecimiento de regiones a partir de semillas en que si el mínimo δ es menor que un umbral predefinido T entonces se agrega a la región respectiva A_j . Si no es así, entonces el píxel se considera significativamente diferente de todas las regiones actuales A_i y se establece una nueva región A_{n+1} con ese píxel (Romero, 2013).

Una variante de esta técnica, propuesta en (1985) se basa en la intensidad de píxel. La media y la dispersión de una región, junto con la intensidad del píxel candidato, se emplean para calcular un test estadístico. Si el valor del test estadístico es suficientemente pequeño, En el caso de que el píxel cumpla con los criterios de similitud predefinidos, se incorpora a la región existente, y se actualizan tanto la media como la dispersión de dicha región. En situaciones opuestas, cuando el píxel no satisface los criterios establecidos, se descarta y se utiliza para iniciar la formación de una nueva región.

- **Método del conjunto de nivel**

La propagación de curvas es una técnica destacada en el análisis de imágenes, utilizada para la extracción de objetos, seguimiento de objetos, reconstrucción en 3D, entre otros. La premisa central de este enfoque radica en guiar el desarrollo de una curva hacia el mínimo potencial de una función de coste, la cual refleja la tarea específica y establece restricciones de suavidad. Las técnicas de Lagrange se fundamentan en la parametrización del contorno según alguna estrategia de muestreo y, a continuación, desarrollan cada elemento conforme a la imagen y sus condiciones internas (Romero, 2013). A pesar de su eficacia, esta técnica enfrenta diversas limitaciones, como la toma de decisiones sobre la estrategia de muestreo, la estimación de las propiedades geométricas internas de la curva, la gestión de cambios en su topología, y el abordaje de problemas en dimensiones superiores, entre otros. En cada caso, una ecuación en derivadas parciales llamada la ecuación del conjunto de nivel es resuelto por diferencia finita (Yao, 2009). El método del conjunto de nivel fue propuesto inicialmente para realizar un seguimiento de interfaces móviles por

(Osher, 1988) y se ha diseminado a través de varios dominios de imágenes a finales de los noventa. Este enfoque se utiliza de manera eficaz para abordar el desafío de la propagación de la curva, superficie, u otras estructuras implícitas. La idea central consiste en representar la evolución del contorno mediante una función con signo, donde su nivel cero corresponde al contorno actual. Luego, al aplicar la ecuación de movimiento de las curvas de nivel, se puede obtener fácilmente un flujo similar de la superficie implícita. Al aplicarse al nivel cero, este reflejará la propagación del contorno. El método del conjunto de nivel ofrece diversas ventajas: es implícito, no requiere parámetros, proporciona una forma directa de estimar las propiedades geométricas de la estructura en evolución, tiene la capacidad de cambiar la topología y es intrínseco.

- **Métodos de particionamiento gráfico**

Este método se utiliza de manera efectiva en la segmentación de imágenes. En estos enfoques, la imagen se modela como un grafo ponderado no dirigido (Felzenszwalb, 2004). En términos generales, un píxel o un conjunto de píxeles se conectan a los nodos, y los pesos de las aristas definen la similitud entre los píxeles vecinos. El grafo, que representa la imagen, se divide según un criterio de diseño que permite modelar de manera eficiente los clusters (Felzenszwalb, 2004). Cada partición de nodos (píxeles) produce, en estos algoritmos, los objetos segmentados presentes en la imagen. En esta clasificación, se encuentran algoritmos reconocidos como cortes normalizados, camino aleatorio, mínimo corte, particionamiento isoperimétrico y árboles de expansión mínima.

- **Transformación divisoria (watershed)**

La transformación de división de aguas (watershed) calcula las líneas divisorias en la imagen. Una imagen en escala de grises puede ser interpretada como un relieve topográfico, donde la intensidad de gris de un píxel se asocia con su altura en el relieve. De manera análoga, la magnitud del gradiente de una imagen puede ser considerada como una superficie topográfica. Los píxeles con gradientes de intensidad más elevados representan las líneas divisorias, indicando los límites entre regiones (Zhang, 2004). Al simular el vertido de agua sobre cualquier píxel rodeado por una línea divisoria, esta fluirá cuesta abajo hacia un mínimo local de intensidad compartido. Los píxeles que convergen hacia un mínimo común forman una cuenca,

representando así un segmento de la imagen, es decir, un objeto (Zhang, 2004).

- **Método del valor umbral (umbralización)**

Su procedimiento de umbralización consiste en establecer límites (umbrales) de tal manera que sus píxeles que se ubiquen en cada par de límites constituyan un objeto durante el proceso de segmentación. En este enfoque, se pueden identificar dos situaciones potenciales:

1. **Umbral único.** Se emplea únicamente cuando existen dos conjuntos discernibles de píxeles en una imagen, es decir, un objeto y el fondo. Se define el umbral único, denotado como T , para separar estos conjuntos. Los píxeles con intensidades superiores al umbral T se asignan al objeto, mientras que los píxeles con intensidades inferiores al umbral T se consideran parte del fondo.
2. **Umbral multinivel.** En el contexto de una imagen que contiene x clases de objetos, se requieren $x-1$ umbrales para separarlos de manera individual. Cada par de umbrales T_i y T_j define un intervalo donde los píxeles que caen entre ellos representarán una clase específica de objeto.

Los umbrales elegidos pueden ser de varios tipos dependiendo de las características tenidas en cuenta para su elección (Kim, 2003).

- **Segmentación basada en modelos**

La idea fundamental de este método es que las estructuras de interés presentan una forma geométrica repetitiva, lo cual impulsa la búsqueda de un modelo probabilístico que explique la variación en dicha forma. Durante el proceso de segmentación de una imagen, se introducen restricciones para considerar la imagen como el modelo predefinido, implicando así:

1. La elección de ejemplos de entrenamiento, son utilizados para evaluar los modelos.
2. La representación probabilística de la variación de los ejemplos seleccionados.
3. Relación estadística que se establece entre el modelo y la imagen.

El estado del arte para la segmentación basada e en el conocimiento implica la forma

activa y los modelos de apariencia, contornos activos y una plantilla deformable y métodos basados en niveles (Haralick, 1985).

- **Segmentación multi-escala**

Estas se computan en múltiples escalas y, en ocasiones, se propagan desde una escala grande hacia una más pequeña. Los criterios de segmentación pueden ser de una complejidad arbitraria y pueden incorporar tanto criterios globales como locales. Un requisito común es que cada región debe estar conectada de alguna manera (Lades, 1993).

- **Segmentación jerárquica de señales unidimensionales**

El trabajo de Wilkin en el espacio escalar introduce la noción de que es posible segmentar de manera inequívoca una señal unidimensional en regiones mediante la utilización de un parámetro que controla la escala de segmentación. En este contexto, se observa que los cruces por cero de las segundas derivadas, es decir, los mínimos y máximos de la primera derivada o pendiente, de versiones suavizadas a diferentes escalas de la señal generan una estructura jerárquica en forma de árbol. Dicha estructura define las relaciones jerárquicas entre los segmentos a diversas escalas. En particular, la pendiente en los extremos a una gran escala se relaciona con las características correspondientes a una escala más pequeña. Cuando una pendiente máxima y una pendiente mínima se cruzan en una escala superior, los tres segmentos que se separaron se fusionan en un solo segmento, definiendo así la jerarquía de los segmentos (Pydipati, 2005).

- **Segmentación Semiautomática**

En este enfoque de segmentación, el usuario define las regiones de interés mediante clics del ratón, y los algoritmos se aplican de manera que se selecciona el camino que mejor se ajusta al borde de la imagen, técnicas como SIOX, Livewire o tijeras inteligentes se utilizan comúnmente en este tipo de segmentación (Shi, 2000).

- **Redes neuronales de segmentación**

Las redes neuronales de segmentación se fundamentan en el procesamiento de pequeñas áreas de una imagen mediante una red neuronal artificial o un conjunto de redes neuronales, por eso, después de este proceso de decisión se construye un

mecanismo que marca las áreas de una imagen de acuerdo a la categoría reconocida por la red neuronal (Palmer, 2002). Las redes neuronales de parejas de pulsos (PCNNs) son modelos neuronales propuestos según los modelos de la corteza visual de un gato y se han desarrollado para lograr un alto rendimiento en el procesamiento de imágenes biomiméticas (Palmer, 2002). El modelo de Eckhorn ofrece una herramienta simple y efectiva para investigar la corteza visual de mamíferos pequeños. Rápidamente, fue reconocido por su aplicación con un considerable potencial en el procesamiento de imágenes (Ponce, 2012). Un PCNN es una red neuronal bidimensional donde cada neurona en la red se asocia con un píxel en una imagen de entrada, recibiendo información de color de su respectivo píxel como estímulo externo. Cada neurona establece conexiones con sus vecinas, recibiendo estímulos tanto de fuentes externas como de estímulos locales. Estos estímulos externos y locales se integran en un sistema de activación interna que acumula la información hasta que se alcanza un umbral dinámico, desencadenando la generación de una salida en forma de pulsos. A través de cálculos iterativos, las neuronas PCNN producen series temporales de impulsos de salidas (Gonzales, 2006).

- **Técnicas de agrupamiento**

La eficiencia de acceder a estos datos y la capacidad de extraer información útil de ellos se han vuelto imperativas. Por esta razón, se han implementado diversas técnicas de análisis automatizado que posibilitan el aprendizaje de la información disponible. Esto mejora la eficiencia en diversas aplicaciones y proporciona conocimientos al reducir la subjetividad asociada a la intervención humana (Mata, 2015).

- **Agrupamiento espectral**

El agrupamiento es una de las técnicas más empleadas para el análisis exploratorio de datos. Busca dividir los puntos de datos en varios grupos, de manera que los puntos en el mismo grupo sean similares entre sí, mientras que los puntos en diferentes grupos sean diferentes entre sí. La agrupación espectral se ha vuelto cada vez más popular debido a su implementación simple y rendimiento prometedor en muchas agrupaciones basadas en gráficos. Se puede resolver de manera eficiente mediante el software estándar de álgebra lineal, y muy a menudo supera a los algoritmos tradicionales, como el algoritmo k-means (Aoullay, 2018).

Este enfoque engloba una etapa de agrupamiento no supervisado que se ejecuta mediante el criterio multiclase de particiones normalizadas (Ordóñez, 2013). Se prefiere esta técnica porque no requiere un algoritmo de agrupamiento adicional. Además, produce una partición resultante apropiada, ya que toma en cuenta la información obtenida de la solución propia, adicionalmente, se aplican medidas de afinidad adecuadas y se realiza la estimación automática del número de grupos con el fin de reducir el tiempo de procesado y mejorar la convergencia del algoritmo (Peluffo, 2016).

Lorenti menciona que los métodos de agrupamiento espectral se basan en los auto vectores y autovalores extremos de las matrices derivadas de los patrones de entrada. A diferencia de los algoritmos de agrupamiento tradicionales, como k-medias, que son eficaces para agrupar patrones con formas geométricas convexas, el agrupamiento espectral puede abordar problemas en escenarios mucho más complejos, como espirales entrelazadas u otras formas no lineales arbitrarias (Lorenti, 2015).

- **Imágenes sin firma digital**

La distribución automática de imágenes sin firma se refiere a la clasificación y manejo de imágenes mediante algoritmos y técnicas automatizadas sin la necesidad de intervenciones manuales específicas para etiquetar o firmar estas imágenes (Chuquillanqui Julcapari 2021), este flujo constante de imágenes también ha planteado desafíos significativos, uno de los cuales es la gestión y distribución de imágenes sin firma. Las imágenes sin firma son aquellas que carecen de metadatos o información adicional que permita identificar a su autor o fuente original, pueden ser imágenes creadas por usuarios anónimos en redes sociales, fotografías compartidas en sitios web sin atribución adecuada o imágenes que han perdido sus metadatos debido a manipulación o descargas en línea (López Carvajal 2016).

- **Grupos espectrales.**

Los grupos espectrales son técnicas de aprendizaje automático que permiten agrupar datos similares en conjuntos o clústeres basados en características comunes. En el contexto de las imágenes sin firma, los grupos espectrales pueden ayudar a organizar y categorizar imágenes de manera efectiva, lo que facilita su gestión y distribución.

La gestión y distribución de grupos espectrales en imágenes hiperespectrales se refiere a técnicas utilizadas para reducir la dimensionalidad de los datos y mejorar su procesamiento y clasificación, para mejorar la eficiencia y precisión (Matthew et al. 2011). Si la distribución de grupos espectrales en imágenes sin firma implica el uso de métodos avanzados para la clasificación y anotación de imágenes, sin depender de información de firma explícita. Esto se logra mediante el análisis de las características espectrales inherentes de las imágenes y el uso de técnicas de agrupamiento espectral para mejorar la precisión y coherencia de las anotaciones automáticas (Dimitri & Arcot 2009).

- **Imágenes espectrales.**

Las Imágenes espectrales, capturan datos en varias bandas espectrales, que son rangos específicos del espectro electromagnético, las imágenes espectrales generalmente abarcan desde el ultravioleta hasta el infrarrojo cercano, divididas en un número limitado de bandas, ahora una firma espectral es un gráfico que muestra la reflectancia o emisión de un material en diferentes longitudes de onda, cada material tiene una firma espectral única que se puede utilizar para identificarlo o diferenciarlo de otros materiales, estas firmas se obtienen midiendo la cantidad de energía reflejada o emitida por un objeto a través de diferentes bandas del espectro. La técnica de mezcla espectral con Lasso de Grupo Escaso y algoritmos como GSUNSAL permiten una distribución eficiente y precisa de firmas espectrales en imágenes sin firma, mejorando la clasificación y la gestión de grupos espectrales en aplicaciones de teledetección y análisis hiperespectral en (Iordache et al. 2009).

1.2. Antecedentes

La visión por computadora, una disciplina prominente de la inteligencia artificial, se emplea ampliamente en la actualidad, desempeñando roles fundamentales en aplicaciones como el control de calidad, la vigilancia y el análisis de imágenes, entre otras. La segmentación de imágenes es uno de los fundamentos de la visión por computador, ya que una interpretación precisa de la realidad depende de esta etapa. La tarea de segmentación implica dividir la imagen en una serie de regiones que no se superponen y que comparten características homogéneas, como intensidad, color, textura, entre otras (Zhao, 2016). Los algoritmos tradicionales de agrupamiento espectral han sido extensamente utilizados en la segmentación de imágenes a lo largo de varias décadas

gracias a su eficacia y su sencilla implementación. Sin embargo, la mayoría de estos algoritmos se enfrentan a desafíos asociados con altos costos computacionales y tiempos de procesamiento prolongados.

La correcta segmentación de imágenes se ve afectada por presencia de ruido y valores atípicos (Liu, 2012) . También Zengse propone un algoritmo basado en modelos de mezclas gaussianas en 2014. En una primera etapa, se modela la distribución conjunta de las características de color y posición mediante una mezcla gaussiana con el objetivo de obtener una aproximación o estimación de la imagen original (Liu, 2012). Se realizan medidas comparativas entre los componentes gaussianos y, finalmente, se fusionan estos componentes utilizando agrupamiento espectral sobre la matriz de similitud. Entre las características destacadas de este algoritmo se encuentran su robustez ante el ruido, su baja sensibilidad a la inicialización, la eficaz extracción de características espectrales y la reducción del tamaño de la matriz de similitud. Sin embargo, es importante señalar que a medida que se aumenta el número de componentes gaussianos utilizados para recrear la imagen, también se incrementa la carga computacional y el riesgo de sobreajuste de datos. El diagrama de Voronoi, fundamentado en los polígonos de Thiessen, tiene como propósito llevar a cabo la teselación de una imagen. Esto implica la subdivisión de la imagen en regiones con polígonos irregulares, conformados por rectas, semirrectas o segmentos de rectas. El diagrama de Voronoi debe cumplir con dos propiedades esenciales: asegurar que no haya áreas no cubiertas en el plano y garantizar que los polígonos no se superpongan. Para lograr esto, se colocan k puntos en la imagen, conocidos como centroides, que definen cada región. Cada píxel de la imagen se vincula al centroide con el que comparta más similitud (Fan, 2015). Filippone (2008) bajo esta técnica los algoritmos FCM funcionan bien siempre que la imagen está formada por regiones homogéneas, pese a que, estos algoritmos sólo tienen en cuenta la información de intensidad de los píxeles, pero no la información espacial, la segmentación de imágenes también se ve afectada por el ruido (Fan, 2015). Proponen el algoritmo FEWCVT (*fuzzy edge- weighted centroidal Voronoi tessellations*), el cual genera una función de similitud difusa combinando la información de intensidad de la imagen con la información de los límites de las agrupaciones. Consiguiendo así bordes más suaves y mayor tolerancia al ruido.

La mayoría de los algoritmos de agrupamiento espectral utilizan la función gaussiana como medida de similitud (Xu, 2013) sin embargo, esta no puede reflejar plenamente la

compleja distribución espacial del conjunto de datos, y es indeseable cuando los grupos de datos se desarrollan sobre una estructura compleja (Zhao, 2010). El problema que se aborda en Li (2016) en el proceso de construcción de la matriz de similitud, es crucial hallar una medida de similitud más robusta entre los pares de datos, en oposición a la medida generada por la función núcleo gaussiano. En este sentido, se presenta un enfoque no supervisado denominado AFSSC (Axiomatic Fuzzy Set-based Spectral Clustering) como una propuesta que capitaliza las características discriminantes para abordar este desafío.

Otra investigación es Yin (2017) en este artículo se presenta un algoritmo de segmentación multinivel sin supervisión. El paso central de nuestro algoritmo es un operador de segmentación de dos niveles, que utiliza cortes de gráficos binarios para maximizar tanto la entropía difusa de 2 particiones como la suavidad de la segmentación. Al realizar de manera iterativa este operador de segmentación de dos niveles, la segmentación de imagen multinivel se logra de manera jerárquica: a partir de la imagen de color de entrada, nuestro algoritmo primero selecciona el canal de color que mejor puede segmentar la imagen en dos etiquetas, y luego selecciona canales de forma iterativa dividir más cada etiqueta hasta la convergencia. Los resultados experimentales demuestran que el esquema de segmentación jerárquico presentado puede segmentar eficientemente imágenes en escala de grises y en color. Las evaluaciones cuantitativas sobre las imágenes grises clásicas y la base de datos de segmentación de Berkeley muestran que nuestro método es comparable a los métodos de segmentación de escala múltiple de última generación, pero tiene la ventaja de ser sin supervisión, eficiente y fácil de implementar.

El trabajo de Shi (2014) proponemos una métrica objetiva para la evaluación de la calidad de la segmentación de objetos individuales en imágenes. Usando el índice Jaccard como base, los términos de compensación adicionales se integran en nuestra métrica. Estos términos no solo permiten que nuestro equipo combine métodos basados en regiones y en límites, sino que también describen la tolerancia visual humana y la saturación. Esta métrica también puede ajustar adaptativamente la "función de percepción" en diferentes tamaños de imagen.

En Xueliang (2015) propone medidas de precisión y recuperación basadas en regiones y las usamos para comparar dos particiones de imágenes con el fin de evaluar la calidad de

la segmentación. Las dos medidas se calculan en función de la superposición de la región y se presentan como un punto o una curva en un espacio de precisión de recuperación, que puede indicar la calidad de la segmentación en aspectos geométricos y aritméticos. Además, las medidas de precisión y recuperación se combinan mediante el uso de cuatro métodos diferentes. Examinamos y comparamos la efectividad de los indicadores combinados a través de la ilustración geométrica, en un esfuerzo por revelar claramente la calidad de la segmentación y capturar la compensación entre las dos medidas. En los experimentos, adoptamos el método de segmentación multirresolución (MRS) para la evaluación. Las medidas propuestas se comparan con cuatro medidas de discrepancia existentes para confirmar aún más sus capacidades. Finalmente, sugerimos utilizar una combinación de la curva de precisión de recuperación basada en la región y la medida F para la evaluación de segmentación supervisada.

Para el trabajo de investigación de Išgum (2015) proporciona tres conjuntos de imágenes diferentes de recién nacidos prematuros, se creó para proporcionar tal comparación. Estos conjuntos son (i) exploraciones axiales adquiridas a 40 semanas de edad corregida, (ii) exploraciones coronales adquiridas a las 30 semanas de edad corregida y (iii) exploraciones coronales adquiridas a 40 semanas de edad corregida. Cada uno de estos tres conjuntos consta de tres imágenes de RM ponderadas en T1 y T2 del cerebro adquiridas con un escáner de resonancia magnética 3T. La tarea consistía en segmentar la materia gris cortical, la materia blanca no mielinizada y mielinizada, el tronco encefálico, Los ganglios basales, el tálamo y el cerebelo son estructuras cerebrales fundamentales en el sistema nervioso central. Cualquier equipo podría subir los resultados y todas las segmentaciones se evaluaron de la misma manera. Este artículo presenta los resultados de ocho equipos participantes. Los resultados demuestran que los métodos participantes pudieron segmentar bien todas las clases de tejidos, excepto la materia blanca mielinizada.

En Martínez (2022) el objetivo de este artículo es evaluar varios algoritmos de segmentación de RV en datos comunes. Más precisamente, informamos aquí los resultados del Desafío de segmentación del ventrículo derecho (RVSC), concretados durante la Conferencia MICCAI'12 con una competencia en el sitio. Se han considerado siete métodos automatizados y semiautomatizados, junto con tres métodos basados en atlas, dos métodos basados previamente y dos métodos libres de imágenes anteriores que utilizan el movimiento cardíaco. Los contornos obtenidos se compararon con un trazado

manual realizado por un radiólogo cardíaco experto, tomado como referencia, utilizando la distancia métrica Dice y la distancia de Hausdorff. En este documento describimos los datos cardíacos compuestos por 48 pacientes, el protocolo de evaluación y los resultados. Los mejores resultados muestran que se puede esperar una precisión de datos promedio del 80% y una distancia de Hausdorff de 1 cm a partir de algoritmos semiautomatizados para esta tarea desafiante en los conjuntos de datos, y que un algoritmo automatizado puede alcanzar un rendimiento similar, a expensas de un alto carga computacional.

En el trabajo de Peng (2017) presenta un marco para evaluar la calidad de la segmentación utilizando múltiples segmentaciones etiquetadas que se consideran referencias. Para evaluar una segmentación, componíamos de forma adaptativa una segmentación de referencia utilizando múltiples segmentaciones etiquetadas, que localmente coinciden con los segmentos de entrada mientras se preserva la consistencia estructural. La calidad de una segmentación dada se mide por su distancia a la referencia compuesta. Se desarrolla un nuevo conjunto de datos de 200 imágenes, donde cada uno tiene de 6 a 15 segmentaciones etiquetadas, para la evaluación del rendimiento de la segmentación de imágenes. Además, para comparar cuantitativamente el algoritmo de evaluación de segmentación propuesto con los métodos más avanzados, se propone un conjunto de datos de evaluación de segmentación de referencia. Se realizan extensos experimentos para validar el marco de evaluación de segmentación propuesto.

Así también en Berezsky (2018) presenta el análisis comparativo de los métodos de segmentación de imágenes biomédicas. El trabajo discute métodos de segmentación sobre la base de etiquetado previo y momentos espaciales. Los resultados experimentales muestran que los métodos desarrollados tienen una mayor precisión por la relación señal-ruido en comparación con los conocidos actualmente.

Una medida de similitud difusa aplicada a la segmentación de imágenes con textura se presenta en (Zhao, 2010). Inicialmente, se genera la matriz de U de agrupamiento difuso, en la cual las filas representan el número de particiones, y las columnas el número total de píxeles según Zhao. Así entonces cada elemento de la matriz contiene el grado de pertenencia del píxel j con respecto a la partición i . En este proceso, cada píxel se caracteriza por un conjunto de 10 atributos, donde los ocho primeros proporcionan información sobre la textura y los dos últimos indican la ubicación espacial (Zhao, 2010). Estos atributos son cruciales para asignar el grado de pertenencia a un grupo específico.

En el siguiente paso, se genera la matriz de similitud utilizando la matriz U . Esta matriz refleja la similitud entre dos píxeles en función de si comparten los mismos grados de pertenencia. Finalmente, se aplican los procedimientos estándar de agrupación espectral para llevar a cabo la segmentación de la imagen (Zhao, 2010).

Finalmente, ya que la matriz de similitud de una imagen representa las afinidades entre todos sus píxeles, su tamaño suele ser demasiado grande, esto hace que sea difícil computar dicha matriz (Baia, 2014). Aplicaciones basadas en súper píxeles abordan esta problemática. Para el desarrollo de súper píxeles se han propuesto varios algoritmos basados en grafos y otros, basados en el crecimiento del gradiente (Achanta, 2011). Uno de los métodos más prometedores para la generación de súper píxeles con bajo costo computacional y gran velocidad de procesamiento se presenta en (Baia, 2014). Se sugiere llevar a cabo la segmentación en dos fases. Primero, se presegmenta la imagen por el método de SLIC (*Simple linear Iterative Clustering*) modificado, donde se extraen las regiones “globales” que contengan características similares (Li, 2012). En segundo lugar, se lleva a cabo el agrupamiento de las regiones presegmentadas en lugar de los píxeles, utilizando el método de Nyström. Este método permite extrapolar la solución de agrupamiento utilizando un pequeño número de muestras (Liu, 2012).

Si la imagen tiene muchos píxeles, se requieren recursos computacionales y un mayor tiempo de procesamiento para resolver la matriz de similaridad. Para resolver el enorme cálculo de la matriz, en Ynag (2016) se introduce un algoritmo de súper píxeles llamado SCS (*Superpixel Spectral Clustering*), el cual permite dividir la imagen en un conjunto conectado de regiones homogéneas (Schick, 2013); con la finalidad de obtener la matriz de similaridad de las regiones resultantes. La técnica SCS se demuestra como altamente estable y apenas se ve afectada por el número de vecinos más cercanos. Además, logra una precisión comparable y supera significativamente el rendimiento en el proceso de agrupamiento en comparación con la mayoría de los algoritmos clásicos (Schick, 2013).

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1. Identificación del problema

La informática como ciencia plantea bastantes retos a los investigadores buscando mejores y más eficientes maneras de contribuir al desarrollo de tecnología con aplicaciones reales y de fácil acceso a la sociedad; también cabe mencionar que el avance de otras ramas complementarias como la electrónica y las telecomunicaciones permiten hoy en día a las personas acceso a dispositivos de fácil conexión a redes de comunicación y a la red de redes Internet. Así las aplicaciones informáticas en la actualidad cobran bastante relevancia para los usuarios debido a que la descentralización de dispositivos y de la Internet son facilitadores de aplicaciones accesibles incluso desde dispositivos móviles entre las que se pueden destacar procesadores de textos en línea, analizadores de voz, procesadores de imágenes, redes sociales entre muchos otros. En tal sentido el área de interés del presente es el de visión por computador pues dado el panorama mostrado anteriormente son factibles también el acceso a aplicaciones que trabajen con imágenes planas e imágenes sobre videos con aplicación a áreas como agronomía para detección de enfermedades foliares, diagnóstico de enfermedades de diversos frutos, o áreas como la medicina o telemedicina que busca diagnósticos de forma distribuida y descentralizada con aplicaciones como calidad de esperma, determinación de calcificaciones en tejidos humanos, también áreas como seguridad para detección de objetos y/o entidades no identificadas. En razón de lo mencionado es notable que las aplicaciones de visión por computador ya son una necesidad del mercado actual y no solo de laboratorios; en razón de ello la presente investigación busca aportar al conocimiento del proceso de segmentación que es parte crucial de un proceso convencional de perspectiva por computador. La segmentación de figuras consiste en que dada una imagen digital se

seleccione y separe un subconjunto de ella conservando las características de interés es decir de un espacio muestral de pixeles se seleccione un sub espacio que reúna condiciones específicas necesitadas. La problemática se ubica en las muchas configuraciones posibles dependientes del dominio I de una imagen en los subconjuntos posibles es decir cómo hacer una selección correcta. En este punto, hay dos aspectos importantes a considerar; el primero es que no hay una única respuesta correcta. Y el segundo aspecto es realizar una partición jerárquica coherente del espacio. Así la tarea de segmentación se enfrenta a esta problemática por lo que las soluciones propuestas deben de garantizar respuestas viables ante los dos aspectos, en ese sentido a continuación se plantea el problema general:

2.2. Enunciados del problema

La interrogante que busca responder la presente investigación es:

¿Cómo realizar la segmentación automática no supervisada de Imágenes digitales?

2.3. Justificación

Desde los primeros trabajos aproximados a entender como los procedimientos para segmentar imágenes usando métodos digitales y que se basa en un modelo de reconocimiento de patrones matemáticos. La técnica no requiere prototipos de entrenamiento, pero presenta las características más útiles para las operaciones en un modo "sin supervisión". Coleman (1984) que enfocaban que las imágenes dadas puedan ser retenidas por el algoritmo sin interacción humana rechazando aquellos atributos que no contribuyen a la agrupación homogénea en el espacio del vector N – dimensional.

Proporcionar capacidad sensorial a un ordenador es una tarea difícil existe hoy un interés especial por dotar a los ordenadores de uno de los cinco sentidos del hombre: La habilidad de ver Gonzales (2006) en las etapas del proceso de visión artificial, la segmentación autónoma es uno de los problemas más difíciles en el procesamiento de la imagen.

Pueden surgir muchas dificultades durante el proceso de segmentación que arrojan resultados incorrectos. Las dificultades clásicas encontradas pueden ser ruido, variación de contraste, falta de homogeneidad en los límites del objeto de interés, artefactos de desenfoque de movimiento (Dietenbeck, 2010).

En términos generales, Los enfoques de evaluación para la segmentación de imágenes pueden ser categorizados en métodos de evaluación analíticos y empíricos. A su vez, los métodos empíricos se pueden clasificar en métodos empíricos de bondad y métodos empíricos de discrepancia. Los métodos analíticos de evaluación generalmente se centran en analizar las propiedades de un algoritmo de segmentación, como su estrategia de procesamiento, complejidad y eficiencia. La evaluación es desde un punto de vista teórico y no requiere la implementación real de los algoritmos (Polak, 2009).

Un gran desafío en la evaluación de la segmentación y el conflicto fundamental entre la generalidad y la objetividad: para la segmentación del propósito general, la verdad básica y la precisión de la segmentación pueden no estar bien definidas, mientras que al incorporar la evaluación en una aplicación específica, los resultados de la evaluación pueden no ser extendido a otras aplicaciones (Ge, 2006).

2.4. Objetivos

2.4.1. Objetivo general

Evaluar la eficacia de la segmentación automática no supervisada de imágenes utilizando el método de agrupamiento espectral.

El principal propósito de este proyecto es presentar un algoritmo para la segmentación de imágenes utilizando la técnica de agrupamiento espectral, con el fin de reducir la cantidad de datos a procesar y optimizar el tiempo de ejecución.

2.4.2. Objetivos específicos

- Implementar una aplicación informática que realice de forma automática la segmentación de imágenes mediante agrupamiento espectral.
- Evaluar la aplicación informática que implementa la segmentación de imágenes mediante agrupamiento espectral.

2.5. Hipótesis

2.5.1. Hipótesis general

La Segmentación Automática de Imágenes mediante el agrupamiento Espectral no supervisado es efectiva.

2.5.2. Hipótesis específicas

- El algoritmo de agrupamiento espectral para la segmentación de imágenes, es efectivo en la etapa de preprocesamiento técnicas de agrupamiento difuso y de súper píxeles.
- El algoritmo de segmentación puede obtener el objeto de interés separado del resto de la imagen.
- El desempeño del algoritmo implementado, comparándolo con una técnica clásica de agrupamiento espectral es eficiente.

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. Lugar de estudio

La región de Puno abarca una extensión territorial de 43,886.36 km² en la zona de sierra, representando el 61.0% del territorio, mientras que la zona de selva comprende 23,101.86 km², equivalente al 32.1%. Además, incluye 14.5 km² de superficie insular (0.02%) y 4,996.28 km² (6.9%) correspondientes a la parte peruana del lago Titicaca. El perímetro fronterizo de la región es de 1,108 km. Puno está ubicado en la latitud -15.8422 y longitud -70.0199, formando parte del continente de América del Sur y situándose en el hemisferio sur. La Región de Puno exhibe una notable diversidad de flora y fauna, tanto silvestre como cultivada y domesticada. Esta riqueza biológica se atribuye a la presencia de lagos, lagunas, ríos y hábitats en diversos ecosistemas, que se extienden desde el anillo circunlacustre del lago Titicaca hasta las áreas de la puna. En estos entornos, se han adaptado especies únicas, como la *Rhea pennata* (Gutierrez, 2012).

La región de Puno destaca por su extraordinaria riqueza en diversidad biológica. De las 84 zonas de vida identificadas en el país, 21 se encuentran en esta región. Además, Puno alberga 7 de las 21 ecorregiones reconocidas, entre las cuales 4 son exclusivas del Perú, como las sábanas del Beni, las yungas bolivianas, las punas húmedas del Titicaca y el lago Titicaca. Estas áreas son hogar de especies de fauna y flora que desempeñan un papel crucial en la estructura trófica de sus ecosistemas, brindando servicios esenciales para el bienestar de la población local.

Es fundamental considerar lo cultural en cualquier proceso educativo, ya que la cultura y su proceso de transmisión son elementos indisolubles. Ambos son procesos dinámicos

que desempeñan un papel esencial en la humanización, dignificación y realización integral del ser humano.

Esta tesis fue llevada a cabo en los laboratorios del Instituto de Investigación en Ciencias de la Computación de la Universidad Nacional del Altiplano, ubicado en el distrito de Puno, provincia de Puno, departamento de Puno.

3.2. Población

La población de datos consta de 15 GB registrados durante un año y comprende imágenes de la base de datos BSD300 (Berkeley Segmentation Dataset), que incluye 600 imágenes a color y en escala de grises. Estas imágenes se distribuyen en un segmento de entrenamiento de 200 imágenes y un bloque de prueba de 100 imágenes. Además, se ofrece la opción de descargar segmentaciones realizadas por personas para estas imágenes.

Así mismo para este trabajo de investigación se expone un algoritmo de segmentación de imágenes basado en agrupamiento espectral, SFSC (*Superpixels, fuzzy and Spectral Clustering*), este enfoque logra segmentar imágenes de gran tamaño más rápidamente que un algoritmo clásico de agrupamiento espectral, y se realiza un análisis comparativo con otras métricas y algoritmos similares (Chilama, 2017).

3.3. Muestra

La muestra es básicamente un segmento más pequeño seleccionado de la población. Podríamos describirla como un conjunto de elementos que son parte de ese grupo específico con características definidas al que nos referimos como población. En realidad, pocas veces es posible medir a toda la población, por lo que obtenemos o seleccionamos una muestra y, desde luego, se pretende que este subconjunto sea un reflejo fiel del conjunto de la población (Sampieri, 2018).

Se utiliza esta fórmula porque se conoce la población y es finita, Cuando se calcula el tamaño de la muestra, se considera un nivel de confianza del 95% y un margen de error de 0.05, utilizando el siguiente estadístico para una población con varianza desconocida:

$$n_0 = \frac{Z^2 * p * q * N}{E^2 * (N - 1) + Z^2 * p * q}$$

Donde:

N = Poblacion 600

n = Tamaño de muestra

Z = Certeza estadística deseada (95% de confianza, valor estándar de 1.96)

p = Probabilidad de acierto (0.5)

q = 1 – Proporción de cobertura (1 – 0.5)

E = error permitido (0.05)

- **Justificación:** La precisión del margen de error (0.05) máximo admisible en términos de proporción se admite cuando existe pocas investigaciones en este campo que se está desarrollando la presente investigación, además es la técnica de muestreo más adecuada, La muestra es representativa de la población.

Reemplazando valores, se tiene:

$$n_0 = \frac{1,96^2 * 0,5 * 0,5 * 600}{0,05^2 * (500 - 1) + 1,96^2 * 0,5 * 0,5}$$
$$n_0 = 45,83 \sim 46$$

En consecuencia, la muestra es de 46.

3.4. Método de investigación

Esta investigación es de clase experimental tecnológico, ya que interviene directamente la variable independiente, que es la segmentación de imágenes, con el fin de medir los efectos en la variable dependiente, que es el método de segmentación no supervisada mediante agrupamiento espectral. Este enfoque se emplea para derivar conclusiones y generalizar los resultados de la investigación de manera cuantitativa.

- **Historias de usuario y tareas de ingeniería**

La historia de usuario es una técnica utilizada para especificar los requisitos de software mediante descripciones breves y comprensibles del comportamiento deseado del programa. Se crean historias de usuario para cada funcionalidad principal del software y ofrecen la ventaja de sustituir documentos extensos de requisitos.

- **Tareas de ingeniería**

Una historia de usuario se fragmenta en una o varias tareas de ingeniería, que describen las actividades a realizar en cada historia, teniendo en cuenta las estimaciones de tiempo. Estas tareas están más centradas en el desarrollador de software, proporcionando un enfoque más directo al código.

- **Diagramas arquitectónicos**

Esta investigación, se utilizaron diagramas de arquitectura., los cuales son representaciones gráficas que muestran cuáles son los componentes físicos y lógicos del sistema de software, así como las relaciones entre ellos. El diagrama de la arquitectura detalla los componentes físicos, como terminales, dispositivos móviles, servidores, entre otros, que forman parte del modelo de composición de microservicios propuesto. Este diagrama también ilustra las relaciones entre dichos componentes y proporciona una explicación detallada de los mismos. Por otro lado, el diagrama de la arquitectura lógica representa los componentes lógicos, es decir, los subsistemas y módulos de la solución de software, así como las relaciones entre ellos. La descripción de esta arquitectura comparte semejanzas con la arquitectura física, ya que se detallan los componentes y las relaciones entre ellos.

3.5. Descripción detallada de métodos por objetivos específicos

a) Para el objetivo general

Determinar la efectividad de la segmentación Automática no supervisada de imágenes mediante agrupamiento espectral. Se plantean tres medidas para medir la efectividad del método propuesto: Segmentación Automática no supervisada de Imágenes mediante agrupamiento espectral, estas son la Puntuación F1, el índice Dice y el índice Jaccard; a continuación, se muestra cada una de estas medidas:

- **Puntaje F1**

En el análisis estadístico de la selección binaria, el puntaje F1 (también conocido como puntaje F o medida F) representa una métrica que evalúa la precisión de una prueba. Este indicador combina tanto la precisión (p) como la recuperación (r) del clasificador para calcular la puntuación (Perez, 2019). La precisión (p) se define como el número de resultados positivos correctos dividido por el número total de resultados positivos

devueltos por el clasificador, mientras que la recuperación (r) es el número de resultados positivos correctos dividido por el número total de muestras relevantes (todas las muestras que deberían haberse identificado como positivas). La puntuación F1 se calcula como el promedio armónico de precisión y recuperación (Ponce, 2012), y su valor óptimo es 1 (indicando precisión y recuperación perfectas), mientras que el valor mínimo es 0.

$$F1(A, B) = \frac{2}{1/P + 1/R} = \frac{2}{|A|/|AB| + |B|/|AB|}$$

- Coeficiente de Sorensen-Dice

El coeficiente ó índice de Sørensen-Dice, también conocido por otros nombres tales como el índice de Sørensen, coeficiente de Dice, es un estadístico utilizado para comparar la similitud de dos muestras (Dice, 1945). El índice de Sørensen utilizado como una medida de distancia, $1 - QS$, es idéntica a la distancia Hellinger y Bray Curtis disimilitud (Bray & Curtis, 1957).

La fórmula original de Sørensen fue concebida para ser aplicada a datos de presencia/ausencia y se define de la siguiente manera:

$$\begin{aligned} Dice(A, B) &= \frac{2|AB|}{|A| + |B|} \\ &= \frac{2|AB|}{(|AB| + |A/B|) + (|AB| + |B/A|)} \\ &= \frac{|AB|}{|AB| + \frac{1}{2}|A/B| + \frac{1}{2}|B/A|} \end{aligned}$$

- Discusión

El mayor número de topologías de clasificación similares se obtuvieron a partir del uso de los coeficientes de similitud de Jacard y Sorensen-Dice. También mostraron el menor número de estructuras pobremente informativas. El mejor comportamiento de estos resultados coeficientes concuerda con los resultados presentados por Hubálek (1982) quien concluyo que estos son los mejores coeficientes en base a una serie de criterios específicos. Nuestros resultados no concuerdan con los de Sánchez y López (1988) quienes concluyeron que el coeficiente de Simpson era adecuado para estudios biogeográficos. Este coeficiente, junto con Kulczynsky 2 produjo porcentajes más bajos de estructuras altamente informativas entre los nueve coeficientes de similitud analizados

tabla 1. Además, mostraron los valores porcentuales más bajos cuando se aplicaron a los datos empíricos, Tabla 4 y 5. En base a nuestros resultados, sorprende que Hubálek (1982) incluyera a Kulczynsky 2 como un buen coeficiente, junto con Jaccard y Sorensen-Dice. Nuestro análisis de datos empíricos resultó en topologías clasificatorias tan diferentes como 51% tabla 4, dependiendo del método de agrupamiento utilizado. Los resultados indican que se debe tener cuidado al seleccionar un método de agrupación. El método de agrupamiento definitivamente influye fuertemente en la topología de clasificación s'. aunque no existen argumentos sólidos a favor de un coeficiente de similitud particular, los análisis de su comportamiento y propiedades ayudan a guiar la elección de un coeficiente. Sin embargo, si se van a utilizar varios coeficientes, se pueden utilizar criterios adicionales como los evaluados en este trabajo. Nuestros resultados sugieren que, en función del número de estructuras poco informativas generadas, el mejor índice a utilizar es Jaccard o Sorensen-Dice, seguido de Braun-Blanquet o Kulczynsky 1.

Las clasificaciones biogeográficas producidas por los métodos de agrupamiento se basan en gran medida en el coeficiente de similitud y los métodos de agrupamiento utilizados. Por lo tanto, como indican nuestros resultados, las clasificaciones obtenidas por métodos cuantitativos, deben ser utilizadas como guías heurísticas para definir regiones biogeográficas. Deben compararse con formas alternativas de análisis, por ejemplo, utilizando principios filogenéticos como en los análisis PAE.

- Índice Jaccard

El índice de Jaccard (IJ) o coeficiente de Jaccard (IJ) mide el grado de similitud entre dos conjuntos, independientemente del tipo de elementos que contengan. La fórmula para calcularlo es la siguiente:

$$Jacc(A, B) = \frac{|AB|}{|A \cup B|}$$
$$= \frac{|AB|}{|AB| + |A \setminus B| + |B \setminus A|}$$

Es decir, la cardinalidad de la intersección de ambos conjuntos dividida por la cardinalidad de su unión. Siempre toma valores entre 0 y 1, correspondiente este último a la igualdad total entre ambos conjuntos (Real y Vargas, 1996).

b) Para los objetivos específicos

- Objetivo específico 1

Implementar una aplicación informática que realice de forma automática la segmentación de imágenes mediante agrupamiento espectral.

- Metodología XP

Una metodología ágil es un enfoque de gestión de proyectos que utiliza ciclos de desarrollo cortos para concentrarse en la mejora continua del desarrollo de un producto o servicio, priorizando la entrega de valor y la adaptabilidad frente a una planificación rigurosa. La metodología XP (Programación Extrema o Xtreme Programming) es un ejemplo de metodología ágil utilizada en el desarrollo de software, que se destaca por su enfoque centrado en la programación de la solución (Letelier *et al.*, 2006).

Además, se señala que el ciclo de vida de un proyecto XP es flexible y dinámico e incluye las siguientes fases, que se presentan en la Figura 8 y se describen a continuación

La fase de planificación define las historias de usuario, que son descripciones de las características que debe tener el sistema de software sin entrar en muchos detalles. Estas historias de usuario constan de tres o cuatro líneas escritas en un lenguaje no técnico para que sean comprensibles y memorizables por el equipo de desarrollo de software (Letelier *et al.*, 2006).

En esta fase de diseño, la metodología XP plantea la creación de diseños simples y sencillos, procurando que sean lo menos complicados posible. El objetivo es obtener un diseño fácilmente entendible e implementable, lo cual facilita el proceso de desarrollo y reduce el tiempo y esfuerzo requeridos.

La etapa de programación se enfoca en establecer estándares de codificación para mantener la consistencia y facilitar la legibilidad y refactorización del código. Esto facilita la comprensión de los requisitos por parte de los desarrolladores. La práctica distintiva de la metodología XP es la programación en pares, donde cada par de programadores escribe su propio código y luego lo integran.

La fase de pruebas es el uso de pruebas para comprobar el funcionamiento del Software que se implementó.

- Objetivo específico 2

Evaluar la aplicación informática que implementa la segmentación de imágenes mediante agrupamiento espectral.

Para la evaluación de la aplicación informática se utilizaron las métricas de calidad de software basadas en el ISO/IEC9126, específicamente las métricas de precisión pertenecientes al grupo de métricas de funcionalidad.

- Métricas de funcionalidad

Las métricas de funcionalidad interna se emplean para anticipar si el producto de software en cuestión cumplirá con los requisitos funcionales establecidos y las necesidades implícitas del usuario.

- Métricas de precisión

Las métricas de precisión interna forman parte del conjunto de métricas de funcionalidad. Estas métricas señalan un conjunto de atributos para evaluar la capacidad del producto de software de obtener resultados correctos o aceptables. A continuación, se presentan las especificaciones de aplicación de la métrica en la siguiente tabla:

Tabla 1

Especificaciones de aplicación de la métrica

Nombre	Propósito	Aplicación	Medición	Interpretación
Exactitud Computacional	¿Cuán completamente se han implementado los requisitos de precisión?	Realice un conteo de las funciones que han implementado los requisitos de precisión y compare este conteo con el número total de funciones que tienen necesidad la precisión.	$X = A / B$ A = Volumen de funciones en las cuales se aplicarequisitos de precisión particulares, según lo validado en la evaluación. B = Cantidad de funciones que requieren la implementación de requisitos de exactitud específicas.	$0 \leq X \leq 1$. Más cercano a 1 más completo
Precisión	¿En qué medida se llevó a cabo de manera exhaustiva la implementación de niveles específicos de precisión para los elementos de datos?	Realice un recuento de los elementos de datos que cumplen con los requisitos de niveles específicos de precisión y compare este recuento con el número total de elementos de datos que tienen requisitos específicos de nivel de precision.	$X = A / B$ A = Cantidad de elementos de datos implementados con grados específicos de exactitud, verificados durante la evaluación. B = Cantidad de elementos de datos que necesitan niveles específicos de exactitud.	$0 \leq X \leq 1$. Cuanto más cerca de 1, más completo.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. Objetivo general

Determinar la efectividad de la segmentación Automática no supervisada de imágenes mediante agrupamiento espectral.

4.1.1. Imágenes de prueba

El conjunto de imágenes generadas para probar la segmentación de **la imagen** sigue la metodología propuesta por (Zhang *et al.*, 2004). Se diseñaron imágenes de 128 x128 compuestas por regiones de intensidad uniforme, además se aplicó un filtro paso bajo logrando mayor realismo, para simular los efectos de ruido se utilizó un filtro gaussiano con media cero y desviaciones estándar de 1, 2 y 4. Estas imágenes se muestran en la figura 6.




Figura 6. K Conjunto de imágenes sintéticas generadas agregando ruido gaussiano con valores de desviación estándar (a) 1, (b) 2 y (c) 4

Fuente: En base a Berkeley Segmentation Dataset (600).

Tabla 2

Datos originales de evaluación basada en la región y peso de los bordes

Pesos originales de la región y peso de bordes							
1	2.131	2.203	1.957	1.673	1.455	1.424	94.501
2	2.589	2.728	2.702	2.723	2.786	3.108	96.313
3	1.655	1.715	1.89	1.941	2.048	2.595	92.621
4	1.094	1.269	1.451	1.587	1.809	2.241	95.728
5	1.759	1.794	1.786	1.734	1.822	2.504	94.678
6	2.546	2.74	2.836	2.851	3.018	3.877	97.095
7	2.052	2.154	2.397	2.552	2.713	3.633	92.902
8	2.784	2.795	2.91	3.01	3.256	3.7	95.477
9	2.058	2.099	2.379	2.619	2.786	4.158	93.677
10	10.224	10.009	10.014	9.778	9.775	9.956	97.302
11	3.81	4.242	4.075	4.401	4.794	5.904	92.688
12	17.933	17.547	17.546	17.426	17.184	16.56	95.184

Fuente: En base a Berkeley Segmentation Dataset (600).

- **Datos originales.** Tabla 2, son los datos originales de la región y peso de bordes de las imágenes.
- **Evaluación de la segmentación.** Tabla 3, Son los pesos relativos de la región e información del borde, como también el número de niveles de multiresolución, son dos parámetros claves del proceso que pueden afectar los resultados de la segmentación, con respecto al primer parámetro, α , indican los pesos de la región de información, mientras que $1 - \alpha$ es el peso dado por los límites de la información. En el rango entre 0 y 1, son considerados siete diferentes valores, por ejemplo, el valor de 3.131 está en función a la suma del incremento más α que sería en este caso $2.131+1=3.131$, y así sucesivamente con esta metodología.

Los resultados de la evaluación de la segmentación desde un esquema base región se visualizan en la Tabla 4, la cual da el nivel de error sobre la segmentación de las imágenes de prueba dadas. Se muestran también el promedio, desviación estándar y la mediana de los porcentajes de error dados como descriptores de la evaluación sobre

todo el conjunto de las imágenes de test. Es notable como resalta un error grande cuando el parámetro de α es configurado con el valor de cero y es considerado solamente la información del borde en el proceso de segmentación.

Tabla 3

Evaluación basada en la región y peso de los bordes

Observaciones							
imagen	$\alpha=1$	$\alpha=0.8$	$\alpha=0.6$	$\alpha=0.5$	$\alpha=0.4$	$\alpha=0.2$	$\alpha=0.0$
1	3.131	3.003	2.557	2.173	1.855	1.624	94.501
2	3.589	3.528	3.302	3.223	3.186	3.308	96.313
3	2.655	2.515	2.490	2.441	2.448	2.795	92.621
4	2.094	2.069	2.051	2.087	2.209	2.441	95.728
5	2.759	2.594	2.386	2.234	2.222	2.704	94.678
6	3.546	3.540	3.436	3.351	3.418	4.077	97.095
7	3.052	2.954	2.997	3.052	3.113	3.833	92.902
8	3.784	3.595	3.510	3.510	3.656	3.900	95.477
9	3.058	2.899	2.979	3.119	3.186	4.358	93.677
10	11.224	10.809	10.614	10.278	10.175	10.156	97.302
11	4.810	5.042	4.675	4.901	5.194	6.104	92.688
12	18.933	18.347	18.146	17.926	17.584	16.760	95.184
Mean	5.220	5.075	4.929	4.858	4.854	5.172	94.847
Std	4.935	4.779	4.747	4.679	4.585	4.270	1.636
Median	3.339	3.266	3.150	3.171	3.186	3.867	94.931

Fuente: En base a Berkeley Segmentation Dataset (600).

A pesar de no mostrar muchas diferencias en los resultados cuando se ajustan los parámetros se evidencia que los resultados más favorables se logran dentro del intervalo de $\alpha = 0.6$ a $\alpha = 0.4$ donde el error de segmentación es cercano al 3% y 4%, o dicho de otra forma el algoritmo segmenta correctamente entre el 87% y 86% de los pixeles de la imagen.

4.1.2. Análisis de varianza

Así mismo se ejecuta un análisis de varianza con el fin de determinar una diferencia estadísticamente significativa entre el ajuste de los parámetros α y el porcentaje de error. Los logros mostrados en la Tabla 04. La tabla de Análisis de varianza señala que existe una diferencia estadística relevante entre los tratamientos dado el valor de significancia con alfa calculado es de $1,5002E-65 <$ al nivel de alfa del 0.05 (5%), es decir esto indica que hay diferencia entre los porcentajes del error del algoritmo de segmentación propuesto debido a la variación del parámetro α .

Tabla 4

Análisis de varianza para los parámetros porcentajes de error debido al ajuste del parámetro α

Origen de las variaciones	Suma de cuadrados	Grados de libertad	Media de los cuadrados	F	Valor crítico para F
Entre grupos	83000.4011	6	13833.4002	725.077757	2.21881674
Dentro de los grupos	1469.04495	77	19.0785058		
Total	84469.446	83			

4.1.3. Prueba post ANVA DMS

Tabla 5


Prueba post ANVA DMS

Pruebas individuales de Fisher para diferencias de las medias						
(I) Niveles de alfa	(J) Niveles de alfa	Diferencia de medias (I-J)	Error estándar	Sig.	95% de intervalo de confianza	
					Límite inferior	Límite superior
	1,00	89.63	1.78	,000	86.08	93.18
7.00	2,00	89.77	1.78	,000	86.22	93.32
	3,00	89.92	1.78	,000	86.37	93.47
	4,00	89.99	1.78	,000	86.44	93.54
	5,00	89.99	1.78	,000	86.44	93.54
	6,00	89.68	1.78	,000	86.12	93.23

- Prueba Post ANVA DMS

- En el análisis de varianza se observó que hay una diferencia significativa entre los tratamientos., se procedió a continuación a determinar los tratamientos que presentan diferencias para eso se utilizó la prueba de comparaciones múltiples para la media DMS. Estos resultados se muestran en la Tabla 6.

Figura 7. Gráfico de medias de los promedios de los errores porcentuales del



algoritmo de segmentación

Fuente: Efectividad de la segmentación automática.

En función al nivel 1,00 su diferencia de media nos da el valor de 89.63, lo cual tiene que ver con con el valor de T, calculado, y el error de la diferencia, se utiliza para determinar la segmentación de las imágenes.

Por otro lado, el valor de 1,78, es el valor del error estándar, que nos indica cuan dispersos están estos valores, en función a la media.

Estos resultados muestran que solo existe diferencias significativas del promedio de los errores porcentuales al aplicar el algoritmo de segmentación de los tratamientos 7 con los tratamientos 1,2,3,4,5,6, es decir solo existe diferencia cuando el parámetro de segmentación α esta configurado a 0, en cambio, la prueba no muestra diferencia estadística significativa entre el promedio de los errores de la aplicación del

algoritmo de segmentación cuando los parámetros están configurados con valores mayores a 0. Se muestra una representación gráfica de esto en la figura 7.

- **Efectividad de la segmentación mediante el Puntaje F1, Coeficiente Dice e Índice Jaccard**

Para ello se desarrollaron experimentos con la base de datos de imágenes “The Berkeley Segmentation Dataset and Benchmark”, esta conjunto de datos consta de 200 imágenes se procedió a realizar pruebas sobre ella a continuación se realizó el cálculo de la similaridad de las imágenes con la finalidad de determinar la efectividad del método de segmentación propuesto. Los resultados de 6 imágenes se visualizan en la Tabla 7. En ella se aprecia los puntajes obtenidos por: el Puntaje **F1**, el **Coeficiente Dice** y el **Índice de Jaccard**. Los puntajes promedio para la efectividad del método de segmentación propuesto se muestran en la Tabla 8, estos resultados fueron calculados mediante la evaluación del método propuesto sobre las 200 imágenes de la base datos, La tabla presenta el promedio de error y la desviación estándar correspondiente a cada métrica de evaluación para el método de segmentación propuesto.

Tabla 6

Resultados de la efectividad del método de segmentación propuesto mediante la evaluación del Puntaje F1, Coeficiente Dice e Índice Jaccard

Nro	Imagen	Puntaje F1	Coeficiente Dice	Índice Jaccard
1		0.88	0.94	0.95
2		0.9	0.89	0.91
3		0.91	0.9	0.92
4		0.94	0.93	0.88
5		0.88	0.88	0.88
6		0.95	0.87	0.87

Los resultados de la Tabla 6 denotan que el método de segmentación propuesto tiene una efectividad promedio de 91.5% mediante el puntaje F1, 90.5% mediante el Coeficiente Dice y una efectividad del 90.7% según el índice de Jaccard.

Tabla 7

Efectividad promedio del método de segmentación

Métrica de evaluación	N	Media	Desviación Estandar
Puntaje F1	200	0.915	0.03028901
Coeficiente Dice	200	0.905	0.02713602
Índice Jaccard	200	0.907	0.02094365

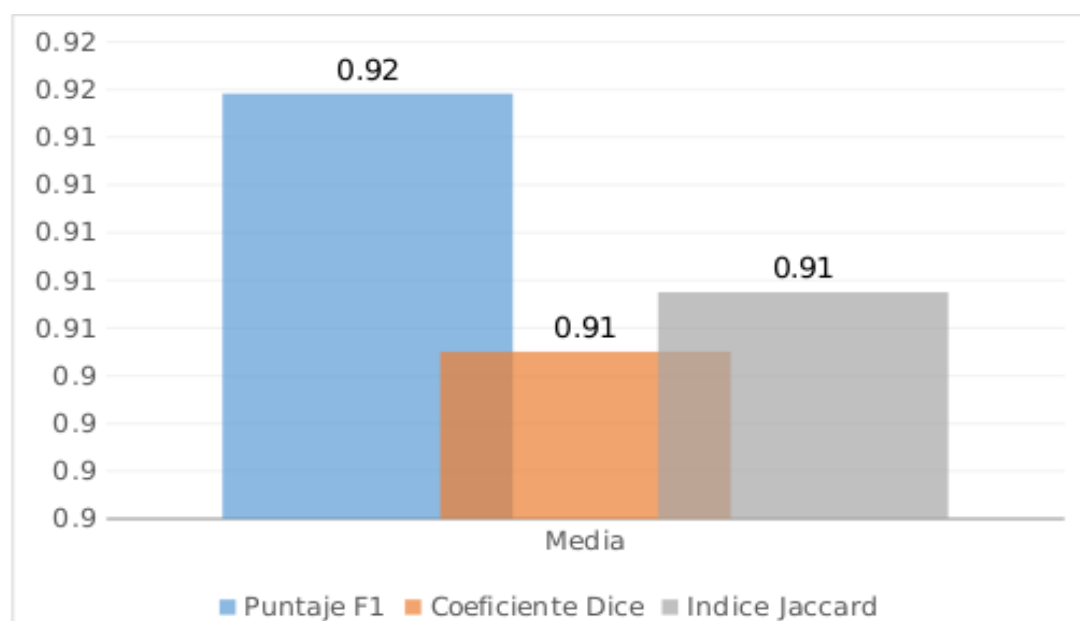


Figura 8. Efectividad según las métricas Puntaje F1, Coeficiente Dice y el Índice de Jaccard

Los resultados mostrados nos indican que el método de segmentación propuesto tiene una efectividad promedio mayor al 90%.

Peng (2017) para evaluar la efectividad de la segmentación uso múltiples segmentaciones etiquetadas en humanos para tener en cuenta la estructura local como la consistencia global de las segmentaciones. Para lograr este objetivo, se construyó una segmentación de referencia de forma adaptativa para una segmentación dada y se usó junto con las medidas propuestas para calcular el puntaje de calidad. Además, presentamos un grupo de segmentación y un conjunto de datos de evaluación con segmentación para facilitar la evaluación cuantitativa de la calidad.

Es importante señalar el estudio de la estructura local como la consistencia global de las segmentaciones, es un punto muy importante a la hora de evaluar una segmentación automática no supervisada. Y así también se uso data sets para segmentaciones de referencias y de forma adaptativa para las pruebas de segmentación.

Zhang (2015) la contribución principal es la construcción de un punto de referencia para la evaluación de la segmentación de imágenes con la suposición de la segmentación del terreno del objeto, es decir, la identificación de la estructura única más perceptualmente relevante de una imagen.

Aquí se puede observar que la identificación de la estructura o forma única es más perceptualmente relevante a la hora de segmentar imágenes automatizados.

- **Objetivos específicos 1**

Implementar una aplicación informática que realice de forma automática la segmentación de imágenes mediante agrupamiento espectral.

Proceso de Segmentación de Imágenes

El proceso de segmentación de imágenes elaborado es mostrado en la Figura 4 que muestra el diagrama de procesos. Como se puede apreciar que desarrollan los procesos:

- Adquisición de Imagen
- Preprocesamiento (Smoothing y Redimensionamiento)
- Conversión de matriz a Vector
- Cálculo de la matriz de similaridad
- Matriz Laplaciana Normalizada/unnormalizada
- Agrupar imágenes para Segmentar - Valores propios y K medias
- Proyectar en la imagen original



Figura 9. Diagrama del software para la segmentación de imágenes

- Implementación de Módulos del software de Segmentación

En esta sección se muestra cada uno de los procesos necesarios para la segmentación de imágenes mediante agrupamiento espectral no supervisado. Estos fueron implementados en el lenguaje de programación R.

- Adquisición de Imagen

Las imágenes utilizadas fueron adquiridas de la data set Berkeley

```
library(jpeg)
```

```
# http://www.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/BSDS300/html/images/plain/normal/gray/86016.jpg
```

```
rawimg=readJPEG("segment.jpeg")
```

```
rawimg=t(rawimg)
```

```
rawimg=rawimg[,ncol(rawimg):1]
```

```
image(rawimg,col = grey((0:12)/12))
```

- Preprocesamiento (Spotting y Redimensionamiento)

El preprocesamiento contiene al suavizamiento de la imagen original para reducir el ruido y el procedimiento de segmentación para reducir el costo computacional del cálculo de la matriz de similitud.

```
#####  
# Smooth the image  
library(fields)  
smoothedImage = image.smooth(rawImage, theta = 2)  
image(smoothedImage, col = grey((0:12)/12))  
#####  
# Reduce Size of Image  
#####  
oldDim = dim(rawImage)  
newDim = c(round(oldDim / 10))  
prod(newDim) > 2^31
```

```
newImage = matrix(NA, newDim[1], newDim[2])
for (r in 1:newDim[1]) {
  centerX = (r-1) / newDim[1] * oldDim[1] + 1
  lowerX = max(1, round(centerX - oldDim[1] / newDim[1] / 2, 0))
  upperX = min(oldDim[1], round(centerX + oldDim[1] / newDim[1] / 2, 0))
  for (c in 1:newDim[2]) {
    centerY = (c-1) / newDim[2] * oldDim[2] + 1
    lowerY = max(1, round(centerY - oldDim[2] / newDim[2] / 2, 0))
    upperY = min(oldDim[2], round(centerY + oldDim[2] / newDim[2] / 2, 0))
    newImage[r, c] = mean(smoothedImage$z[lowerX:upperX, lowerY:upperY])
  }
}
image(newImage, col = grey((0:12)/12))
```

- **Conversión de matriz a Vector**

La matriz de similaridad es construida al obtener el producto cruzado de dos vectores, en este proceso se realiza la conversión de la matriz de la imagen en un vector de datos para obtener a continuación el producto con la imagen de comparación.

```
imgVec = matrix(NA, prod(dim(img)), 3)
counter = 1
for (r in 1:nrow(img)) {
  for (c in 1:ncol(img)) {
    imgVec[counter, 1] = r
    imgVec[counter, 2] = c
    imgVec[counter, 3] = img[r, c]
    counter = counter + 1
  }
}
```

- Cálculo de la matriz de similaridad

El cálculo de la matriz de similaridad es realizada con las imágenes previamente escaladas y convertidas en vectores de datos.

```
pixDiff = 2
sigma2 = 0.01 # var(imgVec[, 3])
simMatrix = matrix(0, nrow(imgVec), nrow(imgVec))
for (r in 1:nrow(imgVec)) {
  cat(r, "out of", nrow(imgVec), "\n")
  simMatrix[r, ] = ifelse(
    abs(imgVec[r, 1] - imgVec[, 1]) <= pixDiff &
    abs(imgVec[r, 2] - imgVec[, 2]) <= pixDiff,
    exp(-(rowSums((imgVec[r, 3] - imgVec[, 3])^2) / (2 * sigma2))),
    0
  )
}
```

- Matriz Laplaciana Normalizada/Nonormalizada

Cálculo de la matriz laplaciana.

```
D = diag(rowSums(simMatrix))
Dinv = diag(1 / rowSums(simMatrix))
L = diag(rep(1, nrow(simMatrix))) - Dinv %*% simMatrix
U = D - simMatrix
```

- Agrupar imágenes para Segmentar - Valores propios y K medias

Este proceso busca agrupar las imágenes mediante su espectro (valores propios calculados) para a continuación realizar una agrupación utilizando el algoritmo de k-medias.

```
evL = eigen(L, symmetric = TRUE)
evU = eigen(U, symmetric = TRUE)
kmL = kmeans(evL$vector[, (ncol(simMatrix) - 1):(ncol(simMatrix) - 0)], centers
```

```
= 2, nstart = 5)

segmatL = matrix(kmL$cluster - 1, newdim[1], newdim[2], byrow = TRUE)

if (max(segmatL) & sum(segmatL == 1))

  kmU = kmeans(evU$ectors[, (ncol(simMatrix) - 1):(ncol(simMatrix) - 0)],
centers = 2, nstart = 5)

  segmatU = matrix(kmU$cluster - 1, newdim[1], newdim[2], byrow = TRUE)

  if (max(segmatU) & sum(segmatU == 1))
```

- **Proyectar en la imagen original**

```
image(segmatL, col = grey((0:15)/15))

image(segmatU, col = grey((0:12)/12))

image(seq(0, 1, length.out = olddim[1]), seq(0, 1, length.out = olddim[2]),
rawing, col = grey((0:12)/12), xlim = c(-.1, 1.1), ylim = c(-.1, 1.1), xlab = "",
ylab = "")

segmat = segmatU

linecol = 2

linew = 3

for (r in 2:newdim[1]) {
  for (c in 2:newdim[2]) {
    if (abs(segmat[r - 1, c] - segmat[r, c]) > 0) {
      xloc = (r - 1) / (newdim[1])
      ymin = (c - 1) / (newdim[2])
      ymax = (c - 0) / (newdim[2])
      segments(xloc, ymin, xloc, ymax, col = linecol, lwd = linew)
    }
    if (abs(segmat[r, c - 1] - segmat[r, c]) > 0) {
      yloc = (c - 1) / (newdim[2])
      xmin = (r - 1) / (newdim[1])
      xmax = (r - 0) / (newdim[1])
    }
  }
}
```

}
}

- Resultados de la implementación

La Tabla 8 muestra los resultados obtenidos por la implementación desarrollada basada en agrupamiento espectral no supervisado. En ella se puede apreciar visualmente como se desarrolla el proceso propuesto y su resultado final.

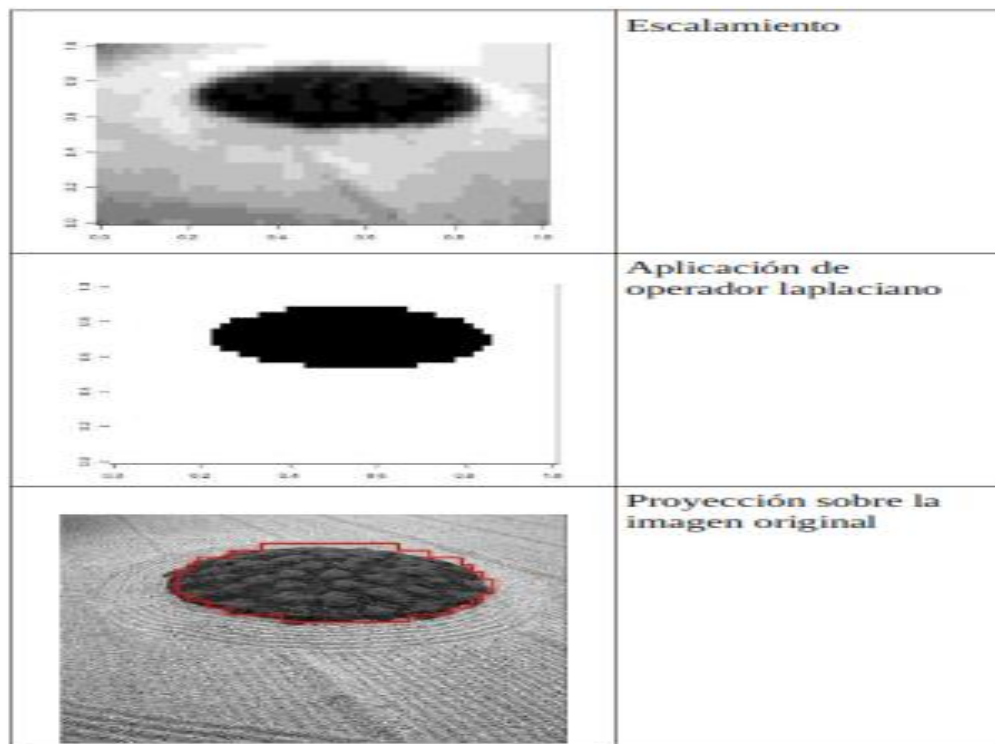


Figura 10. Resultados de la segmentación utilizando la implementación realizada

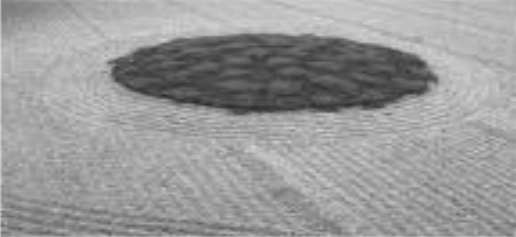

Resultado	Proceso
	<p>Imagen Original</p>
	<p>Suavisamiento</p>

Figura 11. Una efectividad promedio mayor al 90%

- **Objetivos específicos 2**

Implementar una aplicación informática que realice de forma automática la segmentación

- **Exactitud Computacional**

Se realizó el cálculo de la exactitud computacional mediante:

$$X = A / B$$

Donde:

A = Número de funciones en las que se han implementado requisitos de precisión específicos, según lo confirmado en la evaluación.

B = Número de funciones para las que deben implementarse requisitos de precisión específicos

Reemplazando y realizando los cálculos correspondientes se obtuvo:

$$X = 5 / 6$$

$$X = 0.833 \text{ (83\% de exactitud computacional)}$$

Por lo que podemos afirmar que la exactitud computacional del software implementado supera el 80%

Se realizó el cálculo de la Precisión que obedece a la siguiente métrica:

$$X = A / B$$

A = Número de elementos de datos implementados con niveles específicos de precisión, confirmados en la evaluación

B = Número de elementos de datos que requieren niveles específicos de precisión

Reemplazando y realizando los cálculos correspondientes se obtuvo:

$$X = 5 / 6$$

$$X = 0.833 \text{ (83\% de exactitud computacional)}$$

Por lo tanto, podemos afirmar que la exactitud computacional del software implementado es superior al 80%.

CONCLUSIONES

Se concluyó que la eficacia de la segmentación automática no supervisada de imágenes mediante agrupamiento espectral fue evidente a través de los resultados obtenidos. El método de segmentación propuesto exhibió una efectividad promedio del 91.5% según el puntaje F1, del 90.5% mediante el Coeficiente Dice, y una eficacia del 90.7% de acuerdo con el índice de Jaccard. Es decir que el método de segmentación Automática no supervisada de imágenes mediante agrupamiento espectral propuesto tiene una efectividad promedio mayor al 90%.

Se realizó la implementación de una aplicación informática que realiza de forma automática la segmentación de imágenes mediante agrupamiento espectral, esta se realizó en el lenguaje de programación R, y se muestra que se realizó de forma correcta la implementación de los siguientes módulos – Adquisición Preprocesamiento (Smoothing y Redimensionamiento), Vector, Calculo de la matriz de Conversión similaridad, de Matriz Imagen, matriz a Laplaciana Normalizada/ unnormalizada, Agrupar imágenes para Segmentar Valores propios y K medias, Proyectar en la imagen original.

Finalmente se realizó la evaluación de la aplicación informática que implementa la segmentación de imágenes a travez agrupamiento espectral en su métrica de Precisión (Accuracy) en las submétricas de precisión y exactitud computacional. Según aplicación del objetivo específico 2, e implementación de la métrica, estos dieron en ambos casos una seguridad de 83%, que indica que la aplicación que implementó el algoritmo de segmentación espectral realiza la tarea con una precisión del 90%.

RECOMENDACIONES

Se determinó que la efectividad de la segmentación Automática no supervisada de imágenes mediante agrupamiento espectral, en los resultados mostraron que el método de segmentación propuesto alcanza la efectividad promedio de 91.5% mediante el puntaje F1, 90.5% mediante el Coeficiente Dice y una efectividad del 90.7% según el índice de Jaccard. Es decir que el método planteado tiene una efectividad promedio mayor al 80% (Zhang, 2015).

La contribución principal es la construcción de un punto de referencia para el estudio de la segmentación de imágenes con la suposición de la 38 segmentación del terreno del objeto, es decir, la identificación de la estructura única más perceptualmente relevante de una imagen. Una alternativa para mejorar la velocidad de convergencia del agrupamiento espectral, sin sacrificar su efectividad, es diseñar un protocolo de inicialización. Este enfoque de clasificación muestra un desempeño robusto incluso en situaciones donde los grupos no se pueden separar de manera lineal, gracias a la incorporación de información de vectores propios y transformaciones de datos. A pesar de su demanda computacional elevada, la implementación de un protocolo de inicialización puede contribuir a optimizar su eficiencia.

La medida no supervisada relacionada con la coherencia de los grupos, adquirida mediante un criterio particionado espectral, se revela como un indicador efectivo del rendimiento del proceso de agrupamiento. Esto se debe a que penaliza la proliferación de grupos y, con una matriz de afinidad adecuada, produce un valor al margen de 1 para la formación de grupos es precisa. Podemos ver cómo el algoritmo guio este trabajo para desarrollar un método de segmentación de imágenes que resuelve dos problemas principales. primero, reducir los tiempos de ejecución y segundo, lograr la segmentación en regiones coherente en una determinada imagen, de manera que creamos que se han logrado satisfactoriamente los objetivos planteados, la implementación del algoritmo ha notablemente reducido el tiempo en respuesta en comparación con el algoritmo clásico (SC). Esto se debe principalmente a la incorporación de la tecnología de superpíxeles en la fase de segmentación anterior, lo que reduce significativamente el tiempo de ejecución del SFSC. Mientras que el algoritmo clásico opera los píxeles de una imagen, se ve afectado por imágenes más grandes que contienen más de 2500 píxeles, en contraste con el algoritmo propuesto que ha mostrado un buen rendimiento en la segmentación de

imágenes. Imagen segmentada de $100e3$ píxeles. Tenga en cuenta que el rendimiento del algoritmo se degrada a medida que el número de superpíxeles se acerca al número de píxeles de la imagen. Finalmente se realizó la evaluación de la aplicación informática que implementa la segmentación de imágenes mediante agrupamiento espectral en su métrica de Precisión (Accuracy) en las submétricas de precisión y exactitud computacional. Estos dieron en ambos casos una seguridad de 83%, que indica que la aplicación que implementó el algoritmo de segmentación espectral realiza la tarea con una precisión del 83%. Las métricas supervisadas Fop y Fb brindan la oportunidad de evaluar y comparar el desempeño de los métodos de segmentación analizados. En cuanto a las métricas no supervisadas como V, E y Q (Lorenti, 2019), facilitan la distinción entre los distintos algoritmos, aunque de manera menos evidente que en el caso de las métricas supervisadas. Al contrastar el algoritmo desarrollado con otros métodos de segmentación, se observaron resultados favorables en varias métricas de validación., tanto internas como externas. Se sugiere la expansión de la caracterización de los píxeles incorporando otras propiedades, como descriptores difusos, para capturar la imprecisión en la caracterización de un píxel.

La mayoría de los algoritmos de agrupamiento espectral utilizan la función gaussiana como medida de similitud (Xu, 2013) pero no puede reflejar completamente la distribución espacial compleja de un conjunto (Li, 2016) y no es deseable cuando los conjuntos de datos se construyen en una estructura compleja (Zhao, 2011). El problema discutido en (Li, 2016) es que para construir una matriz de similitud, es necesario encontrar una medida más confiable de similitud entre pares de datos, a diferencia de la que genera la función de multiplicación gaussiana. Se ha propuesto un método no supervisado llamado AFSSC (Axiom Fuzzy Spectral Clustering) utilizando funciones discriminantes. Este método permite la recopilación y conexión de información similar dispersa en subespacios, lo que permite una detección más precisa de la distribución de datos.

Para lograr este objetivo propuesto se debe integrar la base de datos de imágenes, aplicar la segmentación de agrupamiento espectral y evaluar y determinar los mejores resultados al realizar las tareas de segmentación.

BIBLIOGRAFÍA

- Al Bashish, D., Braik, M. & Bani-Ahmad, S. (2010). A framework for detection and classification of plant leaf and stem diseases. *Proceedings of the 2010 International Conference on Signal and Image Processing, ICSIP 2010*, 113–118. <https://doi.org/10.1109/ICSIP.2010.5697452>
- Aoullay, A. (2018). *Agrupación espectral para principiantes*. 3–7. <https://doi.org/https://medium.com/datos-y-ciencia/introducci%C3%B3n-a-los-modelos-de-agrupamiento-en-r-72739633e8f3>
- Arbeláez, P., Maire, M., Fowlkes, C. & Malik, J. (2011). Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(5), 898–916. <https://doi.org/10.1109/TPAMI.2010.161>
- Berezsky, O., Batko, Y., Melnyk, G., Verbovy, S. & Pitsun, O. (2016). *Segmentation algorithms of biomedical images: development and quantitative evaluation*. 104–115. <https://doi.org/http://dspace.nbu.gov.ua/handle/123456789/132075>
- Bray, J. R. & Curtis, J. T. (1957). An Ordination of the Upland Forest Communities of Southern Wisconsin. *Ecological Monographs*, 27(4), 325–349. <https://doi.org/10.2307/1942268>
- Castillo, H. N. & Diaz, M. c. (2016). *Procesamiento de imágenes dermatológicas para asistencia al diagnóstico médico*. 130.
- Coleman, B. (1984). Image Understanding Systems. *Proceedings of the IEEE Conference on Decision and Control*, 591. <https://doi.org/10.1109/cdc.1984.272070>
- Chuquillanqui Julcapari, Eliana Aliz. Clasificaciones de imágenes en el lenguaje R. Maestría, España: universidad complutense de madrid, 2021. <https://docta.ucm.es/entities/publication/1c3f22d9-3b8a-4bc8-8776-7d175f4d2568>
- Dass Rajeshwar, S. D. (2016). Image Segmentation Techniques. *Computer Vision Technology for Food Quality Evaluation: Second Edition*, 7109, 45–63. <https://doi.org/10.1016/B978-0-12-802232-0.00002-5>

- Díaz, R. & Cañas, J. M. (2016). *Contador de personas con sensor RGBD*. 73. Retrieved from <http://creativecommons.org/licenses/by-sa/4.0/>
- Dice, L. R. (1945). Measures of the Amount of Ecologic Association Between Species Author (s): Lee R. Dice Published by: Ecological Society of America Stable URL : <http://www.jstor.org/stable/1932409>. *Ecology*, 26(3), 297–302.
- Dietenbeck, T., Alessandrini, M., Friboulet, D., Bernard, O., Lyon, U. De, Umr, C., ... Cedex, F. V. (2010). CREASEG: A free software for the evaluation of image segmentation algorithms Based On Level-Set Arces, University of Bologna, Bologna, Italy. *Image Rochester NY*, (1), 665–668. <https://doi.org/10.1109/ICIP.2010.5652991>
- Dimitri, Semenovich, y Sowmya Arcot. «A spectral method for context based disambiguation of image annotations.» School of Computer Science and Engineering University of New South Wales, NSW 2052, Australia, 2009: 1-4. <https://doi.org/10.1109/ICIP.2009.5414229>
- Dougherty, G. (2009). *Digital Image Processing for Medical Applications*. United States of America by Cambridge University Press.
- Fan, F., Ma, Y., Li, C., Mei, X., Huang, J. & Ma, J. (2017). Hyperspectral image denoising with superpixel segmentation and low-rank representation. *Information Sciences*, 397–398, 48–68. <https://doi.org/10.1016/j.ins.2017.02.044>
- Felzenszwalb, P. F. & Huttenlocher, D. P. (2004). Efficient graph-based image segmentation. *International Journal of Computer Vision*, 59(2), 167–181. <https://doi.org/10.1023/B:VISI.0000022288.19776.77>
- Ge, F., Wang, S. & Liu, T. (2006). Image-segmentation evaluation from the perspective of salient object extraction. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1, 1146–1153. <https://doi.org/10.1109/CVPR.2006.147>
- Gonzales, A., Martines, F. J., Pernia, A. y Alba, F. (2006). *Técnicas y algoritmos básicos de vision artificial*. Universidad de La Rioja.



- Haralick, R. M. & Shapiro, L. G. (1985). Image segmentation techniques. *Computer Vision, Graphics, & Image Processing*, 29(1), 100–132. [https://doi.org/10.1016/S0734-189X\(85\)90153-7](https://doi.org/10.1016/S0734-189X(85)90153-7)
- Işgum, I., Benders, M. J. N. L., Avants, B., Cardoso, M. J., Counsell, S. J., Gomez, E. F., ... Viergever, M. A. (2015). Evaluation of automatic neonatal brain segmentation algorithms: The NeoBrainS12 challenge. *Medical Image Analysis*, 20(1), 135–151. <https://doi.org/10.1016/j.media.2014.11.001>
- Iordache, Marian-Daniel, Jose M Bioucas-Dias, y Antonio Plaza. «A spectral method for context based disambiguation of image annotations.» School of Computer Science and Engineering, 2009: 1-4. <https://doi.org/10.1109/ICIP.2009.5414229>
- Kim, H. S. & Kwon, N. (2003). The advantage of network size in acquiring new subscribers: A conditional logit analysis of the Korean mobile telephony market. *Information Economics and Policy*, 15(1), 17–33. [https://doi.org/10.1016/S0167-6245\(02\)00070-7](https://doi.org/10.1016/S0167-6245(02)00070-7)
- Lades, M., Member, S., Vorbriiggen, J. C., Buhmann, J., Lange, J. & W, R. P. (1993). Distortion invariant object recognition in the dynamic link architecture. *IEEE Transactions on Computers*, 42(3), 300–311.
- Letelier, P. y Penadés, M. (2006). Metodologías ágiles para el desarrollo de software: eXtreme Programming (XP). *Técnica Administrativa*, 5(26), 1.
- Lorenti, L. & Giacomantone, J. (n.d.). *Segmentación espectral de imágenes utilizando cámaras de tiempo de vuelo*. 430–439.
- López Carvajal, Jaime. Metodología para el análisis automático de imágenes de sensores remotos de alta resolución basada en líneas. Doctor, Medellín, Colombia: Grupo de Investigación y Desarrollo en Inteligencia Artificial, 2016. <https://repositorio.unal.edu.co/bitstream/handle/unal/77241/10134519.2016.pdf>
- M.Radha, M. (2011). Edge Detection Techniques for. *International Journal of Computer Science & Information Technology (IJCSIT)*, 3(6), 259–267. <https://doi.org/10.1378/chest.1836158>

- Macedo-Cruz, A., Pajares-Martinsanz, G. y Santos-Peñas, M. (2010). Clasificación no supervisada con imágenes a color de cobertura terrestre. *Agrociencia*, 44(6), 711–722. <https://doi.org/http://www.scielo.org.mx/pdf/agro/v44n6/v44n6a10.pdf>
- Mata, M. C. y González-vidal, J. J. (2015). *Técnicas de clustering aplicadas a la discriminación de pigmentos en espectroscopía Raman*. 1–50. https://doi.org/https://upcommons.upc.edu/bitstream/handle/2117/100391/Memoria_MC_E.Raman.pdf?sequence=1&isAllowed=y
- Matthew A, Lee, Bruce Lori Mann, y Prasad Saurabh. «Concurrent spatial-spectral band grouping: Providing a spatial context for spectral dimensionality reduction.» Electrical and Computer Engineering Department, Geosystems Research Institute, Mississippi State University, Mississippi State, MS, 39762., 2011: 1-4. <https://doi.org/10.1109/WHISPERS.2011.6080949>
- Meunkaewjinda, A., Kumsawat, P., Attakitmongcol, K. & Srikaew, A. (2008). Grape leaf disease detection from color imagery using hybrid intelligent system. *5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, ECTI-CON 2008*, 1, 513–516. <https://doi.org/10.1109/ECTICON.2008.4600483>
- Oh, C., Ham, B. & Sohn, K. (2017). Robust interactive image segmentation using structure-aware labeling. *Expert Systems with Applications*, 79, 90–100. <https://doi.org/10.1016/j.eswa.2017.02.031>
- Palmer, A., Montañó, J. J. & Jiménez, R. (2002). Tutorial sobre Redes Neuronales Artificiales: Los Mapas Autoorganizados de Kohonen. *Psicologia.Com*, 6(1).
- Peluffo, D. y Tech, Y. (2016). *Agrupamiento espectral multiclase basado en particiones normalizadas*. (June).
- Peng, B., Zhang, L., Mou, X. & Yang, M. H. (2017). Evaluation of Segmentation Quality via Adaptive Composition of Reference Segmentations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(10), 1929–1941. <https://doi.org/10.1109/TPAMI.2016.2622703>
- Petitjean, C., Zuluaga, M. A., Bai, W., Dacher, J. N., Grosgeorge, D., Caudron, J., ... Yuan, J. (2015). Right ventricle segmentation from cardiac MRI: A collation

- study. *Medical Image Analysis*, 19(1), 187–202.
<https://doi.org/10.1016/j.media.2014.10.004>
- Polak, M., Zhang, H. & Pi, M. (2009). An evaluation metric for image segmentation of multiple objects. *Image and Vision Computing*, 27(8), 1223–1227.
<https://doi.org/10.1016/j.imavis.2008.09.008>
- Pydipati, R., Burks, T. F. & Lee, W. S. (2005). Statistical and neural network classifiers for citrus disease detection using machine vision. *Transactions of the American Society of Agricultural Engineers*, 48(5), 2007–2014.
<https://doi.org/10.13031/2013.19994>
- Real, R. & Vargas, J. M. (1996). The probabilistic basis of Jaccard's index of similarity. *Systematic Biology*, 45(3), 380–385. <https://doi.org/10.1093/sysbio/45.3.380>
- Román-Roldán, R., Gómez-Lopera, J. F., Atae-Allah, C., Martínez-Aroza, J. & Luque-Escamilla, P. L. (2001). A measure of quality for evaluating methods of segmentation and edge detection. *Pattern Recognition*, 34(5), 969–980.
[https://doi.org/10.1016/S0031-3203\(00\)00052-2](https://doi.org/10.1016/S0031-3203(00)00052-2)
- Seemann, T. (2002). Digital Image Processing using Local Segmentation. *Philosophy*, (April), 1–300.
- Shi, J. & Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8), 888–905.
<https://doi.org/10.1109/34.868688>
- Shi, R., & Ngan, K. (2014). Ran SHI, King Ngi NGAN, Fellow, IEEE, and Songnan LI Department of Electronic Engineering, The Chinese University of Hong Kong, Hong Kong. *International Conference on Image Processing(ICIP)*, 4457–4461.
<https://doi.org/10.1109 / ICIP.2014.7025904>
- Unnikrishnan, R., Pantofaru, C. & Hebert, M. (2006). *A Measure for Objective Evaluation of Image Segmentation Algorithms*. 34–34.
<https://doi.org/10.1109/cvpr.2005.390>

- Wang, Z. & Yang, M. (2010). A fast clustering algorithm in image segmentation. *ICCET 2010 - 2010 International Conference on Computer Engineering and Technology, Proceedings*, 6, 592–594. <https://doi.org/10.1109/ICCET.2010.5486041>
- Yao, Q., Guan, Z., Zhou, Y., Tang, J., Hu, Y. & Yang, B. (2009). Application of support vector machine for detecting rice diseases using shape and color texture features. *2009 International Conference on Engineering Computation, ICEC 2009*, 79–83. <https://doi.org/10.1109/ICEC.2009.73>
- Yin, S., Qian, Y. & Gong, M. (2017). Unsupervised hierarchical image segmentation through fuzzy entropy maximization. *Pattern Recognition*, 68, 245–259. <https://doi.org/10.1016/j.patcog.2017.03.012>
- Zhang, D., Yang, J., Frangi, A. F. & Yang, J. Y. (2004). Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(1), 131–137. <https://doi.org/10.1109/TPAMI.2004.1261097>
- Zhang, H., Fritts, J. E. & Goldman, S. A. (2004). *An Entropy-based Objective Evaluation Method for Image Segmentation*. 5307. <https://doi.org/10.1117/12.527167>
- Zhang, X., Feng, X., Xiao, P., He, G. & Zhu, L. (2015). Segmentation quality evaluation using region-based precision and recall measures for remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102, 73–84. <https://doi.org/10.1016/j.isprsjprs.2015.01.009>

ANEXOS

Anexo 1. Matriz del problema de investigación

Título: “Segmentación automática no supervisada de imágenes mediante agrupamiento espectral”

Variables	Dimensión	Indicadores	Valoración de la variable
Variable Independiente. Efectividad de la Segmentación automática no supervisada de imágenes mediante agrupación espectral.	Desarrollo del modelo	- Conceptualización, análisis y desempeño de la segmentación. - Pruebas del entorno con datasets. -Prueba y administración de los cambios	No aplica
	Aplicación del modelo	- Aplicación para medir la efectividad del método propuesto. - Filtros gaussiano. - Filtros paso bajo.	Precisión y recuperación perfecta.
Variable Dependiente. Método de segmentación no supervisada mediante agrupamiento espectral.	Aspectos a evaluar	- Procesamiento - Conversión de matriz a vector - Calculo de la matriz de similaridad. - Matriz laplaciana. - Agrupar imágenes para segmentar.	- Puntuación F1. - Índice Dice. - Índice Jaccard

Anexo 2. Clustering espectral

Dado un conjunto de patrones $X = \{x_1, x_2, \dots, x_n\} \in \mathbb{R}^m$, y una función de semejanza $d: \mathbb{R}^m \times \mathbb{R}^m \rightarrow \mathbb{R}$, es posible construir una matriz de afinidad W tal que $W(i, j) = d(x_i, x_j)$. Los algoritmos de agrupamiento espectral obtienen una representación de los datos en un espacio de dimensión inferior resolviendo el siguiente problema de optimización:

$$\begin{aligned} \max_{U \in \mathbb{R}^{n \times k}} \quad & \text{Tr } U^T L U \\ \text{s.a.} \quad & U^T U = I \end{aligned}$$

donde $L = D^{-1/2} W D^{-1/2}$ es la matriz laplaciana de W de acuerdo a (A. Y. Ng, 2002) y D es una matriz diagonal con la suma de las filas de W ubicadas en su diagonal principal. Una vez obtenido U sus filas son consideradas como las nuevas coordenadas de los patrones. En esta nueva representación es más sencillo aplicar un algoritmo de clustering tradicional [22]. Es posible obtener una aproximación a las coordenadas en este nuevo espacio calculando las afinidades de un pequeño conjunto de píxeles y aproximando las afinidades restantes.

Es posible obtener una aproximación a las coordenadas en este nuevo espacio calculando las afinidades de un pequeño conjunto de píxeles y aproximando las afinidades restantes. Sea $A \subset X$ un subconjunto de patrones muestreados y $B = V - A$, el resto de los patrones no muestreados. W_A es la matriz de semejanza derivada de los datos de A y L_A es la matriz laplaciana de W_A . W_B y L_B son las matrices correspondientes de las afinidades de los puntos de A y B . Es posible definir a L como:

$$\hat{W} = U \Lambda U^T = \begin{bmatrix} A & B \\ B^T & B^T A^{-1} B \end{bmatrix}$$

Es posible obtener una aproximación de W , denominada \hat{W} , solamente a partir de A y B :

Con el objetivo de obtener los autovectores de la matriz laplaciana aproximada, $\hat{L} = D^{-1/2} \hat{W} D^{-1/2}$, es necesario calcular \hat{L}_A y \hat{L}_B :

$$L_{Aij}^{\hat{}} = \frac{W_{Aij}}{\sqrt{\hat{d}_i \hat{d}_j}} \quad \left[\begin{array}{c} \\ \\ \end{array} \right]$$

$$L_{Bij}^{\hat{}} = \frac{W_{Bij}}{\sqrt{\hat{d}_i \hat{d}_{j+|A|}}} \quad \left[\begin{array}{c} \\ \\ \end{array} \right]$$

$$\left[\begin{array}{cc} B^t & B^t A^{-1} B \end{array} \right]$$

donde $\hat{d} = W^{-1}$. Si $L^{\hat{}}A$ es positiva definida, es posible hallar los autovectores ortogonales aproximados en un solo paso. Sea $S = L^{\hat{}}A + L^{\hat{}}A^{-1} 2L^{\hat{}}BL^{\hat{}}B^T L^{\hat{}}A^{-1} 2$ y su diagonalización $S = US\Lambda S^{-1}$, Fowkles et al. [23] demostraron que si la matriz V se define como

$$V = \begin{bmatrix} \hat{L}_A \\ \hat{L}_B^T \end{bmatrix} \hat{L}_A^{-\frac{1}{2}} U_S \Lambda_S^{-\frac{1}{2}}$$

$L^{\hat{}}$ es diagonalizada por V y por Λ_S y $V^T V = I$

Medidas de evaluación supervisadas

Efectividad Precisión y Recall

El objetivo de un método de segmentación es alcanzar una detección perfecta, es decir, $P_m = P_{gt}$. Si esto no sucede es posible analizar los siguientes conjuntos para determinar la calidad de una segmentación:

- Verdadero positivos: Píxeles que son detectados como objetos y son etiquetados de la misma manera en el ground truth. $TP = P_m \cap P_{gt}$
- Falsos positivos: Píxeles que son detectados como no-objetos, pero están etiquetados del mismo modo en el ground truth: $FP = P_m \cap N_{gt}$.
- Falsos negativos: Píxeles que son clasificados como no-objetos pero se encuentran etiquetados como objetos en el ground truth. $FN = N_m \cap P_{gt}$.

El objetivo es maximizar los verdaderos positivos y al mismo tiempo minimizar los falsos positivos y falsos negativos. Un par de medidas ampliamente utilizadas para determinar la calidad del algoritmo de detección es la siguiente:

Precisión: Medidas del porcentaje de píxeles detectados que son realmente verdaderos:

$$\text{Precisión} = |TP| / |P_m| = |P_m \cap P_{gt}| / |P_m| \leq 1$$

Exactitud: Mide el porcentaje de puntos positivos en el ground-truth que fueron detectados correctamente: $\text{Exactitud} = |TP| / |P_{gt}| = |P_m \cap P_{gt}| / |P_{gt}| \leq 1$

Nuestro objetivo es maximizar ambas medidas, pero por lo general existe un compromiso entre ambas. Por ejemplo, marcar toda la imagen como un objeto nos da la mayor cantidad de verdaderos positivos y falsos negativos y una gran cantidad de falsos positivos. Es decir que nos da un recall perfecto, pero una muy baja precisión. Con el objetivo de medir el trade-off entre las dos medidas, la medida F se define como la media armónica pesada entre precisión y recall:

$$F_B = (1 + B^2) \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Donde B nos permite pesar la precisión y el recall de forma diferente. Si se le otorga la misma importancia a ambas medidas, entonces la medida F es la media armónica.

$$F_1 = 2 \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

En términos de detección de verdaderos y falsos, esta medida puede ser reescrita como:

$$F = \frac{2|TP|}{2|TP| + |FN| + |FP|}$$

Coefficiente de Jaccard

El coeficiente de semejanza de Jaccard El índice de Jaccard fue introducido en el contexto de la sociología de la fitosociología en 1901 (Jaccard., 1901), y en el contexto de la segmentación de objetos es usualmente denominado como la Intersección sobre la unión (IoU por sus siglas en inglés) entre los resultados de un método automático y el ground truth:

$$J(P_m, P_{gt}) = \frac{|P_m \cap P_{gt}|}{|P_m \cup P_{gt}|} = \frac{|TP|}{|TP| + |FN| + |FP|}$$

de una segmentación se define de la siguiente manera: $JQM((P_m, P_{gt})) = \frac{|FP| + |FN|}{|P_{gt}|} = 1 - \frac{|TP| - |FP|}{|P_{gt}|}$

La medida espacial de calidad propuesta por el comité MPEG7 para determinar la calidad de una segmentación se define de la siguiente manera:

Este enfoque no toma en cuenta el tamaño de la región considerada $|P_m|$, de forma que el comportamiento no es consistente para regiones de distinto tamaño. La medida de Jaccard y la medida F están relacionados mediante:

$$\frac{F}{2 - F} = J$$

Anexo 3. Manual del usuario

El objetivo de esta guía es orientar el óptimo funcionamiento y desarrollo de los distintos procesos de instalación de complementos y el correcto uso de la aplicación desarrollada, y servir como herramienta de apoyo y mejora del “Registro”. La guía se divide en dos partes.

Instalación de librerías

En esta sección se aplica la instalación y configuración de las librerías. Puntualmente se da una descripción general de cada librería, las páginas de descarga, los pasos para la descarga y los comandos de consola con el fin de concluir una triunfante instalación.

Intel® Math Kernel Library (Intel® MKL)

Es una biblioteca de rutinas matemáticas optimizadas para ciencias, ingeniería y aplicaciones financieras. Las funciones matemáticas principales incluyen las bibliotecas BLAS, LAPACK y ScaLAPACK, solucionadores dispersos, transformadas rápidas de Fourier y matemática de vectores. Las rutinas en MKL están optimizadas a mano, explotando los procesadores multicore y de many core actuales, unidades vectoriales de mayor longitud de palabra y otras características relacionadas con la arquitectura del procesador. La biblioteca MKL ayuda a los desarrolladores a concentrarse en el dominio de la aplicación, ahorrando tiempo y costes de desarrollo, depuración y mantenimiento. Los pasos para su instalación son:

1. Ir al centro de registro de productos de software Intel® y registre el producto proporcionando su e-mail y número de serie, si ha realizado la compra del software. Sin embargo, Intel permite la descarga de forma gratuita aceptando un acuerdo de licencia de uso comercial del software.

Para ello, debe ingresar a su página de internet: <https://software.intel.com/en-us/intel-mkl> seleccionar el software, introducir algunos datos personales (nombre y apellido del usuario, correo electrónico, tipo de usuario (individual), etc...), la página se redireccionará automáticamente y mostrará un número de serie con el cual se puede realizar la instalación del programa. Debajo del número de serie con el cual se puede realizar la instalación del programa. Debajo del número de serie aparecerá un enlace para proceder a la descarga. Antes de pulsar, conviene copiar o apuntar el número de

serie, aunque la página enviara un correo electrónico a la cuenta especificada con la clave generada.

2. Si la cuenta de inicio de sesión no tiene acceso administrativo y el directorio de instalación requiere privilegios de escritura administrativa del sistema (por ejemplo */opt/Intel*), es posible que necesite la ayuda del administrador del sistema para instalar los paquetes.

Instalación MKL

El proceso de instalación de MKL, una vez descargado es el siguiente:

1. Ejecutar el script `install_GUI.sh` ubicado en el nivel superior del archivo de instalación como se muestra en la figura 1. El panel izquierdo de la ventana de instalación proporciona un informe del progreso de instalación, los pasos que se ejecutan en la instalación son:

- Acuerdo de licencia
- Requisitos previos
- Activación de licencia
- Programa Intel® de mejora de software
- Opciones
- Instalación
- Completar

Leer y aceptar los términos del acuerdo de licencia de usuario final (CLUF), hacer clic en el botón Guardar, de ese modo el texto del acuerdo de licencia se almacena en el sistema, hacer clic en el botón siguiente.


```
1 root@localhost:~# tar xzvf l_mkl_2017.0.098.tgz
2 root@localhost:~# cd l_mkl_2017.0.098/
3 root@localhost:~# ./install_GUI.sh
```



Figura 12. Pantalla de carga de Intel® MKL

2. Revisar el cuadro de dialogo Requisitos previos, distribución Linux de x64, el soporte de compiladores de C/C++ y Fortran para Linux, soporte de MKL para la distribución de Linux, implementación de MPI (MPICH2 versión 1.5 o Open MPI 1.8X). Con esto se verifica si el sistema esta configurado correctamente para la instalación, puede continuar con la instalación si están ausente los prerequisites opcionales. Sin embargo, si hace falta corregir un requisito crítico, debe antes corregirlo para asi poder continuar. Cuando se termine haga clic en el botón siguiente.
3. Elegir una de las opciones de activación como muestra en la figura 1; seleccionando alguno de los botones de las opciones correspondientes:
 - Utilizar licencia existente: seleccione esta opción si tiene un archivo de licencia valido.
 - Utilice el número de serie para activar e instalar el producto: elija esta opción si tiene un número de serie. Esta opción requiere una conexión a internet.

- Evalué este producto (no se requiere número de serie): elija esta opción si no lo hace tiene un numero de serie o si desea activar el producto mas adelante. Esta opción no es disponible para las versiones beta.
- Elegir activación alternativa: seleccione esta opción si desea realizar una de las siguientes:
 - Activar offline (utilizando un archivo de licencia)
 - Usar un administrador de licencias

Cuando termine, hacer clic en siguiente.

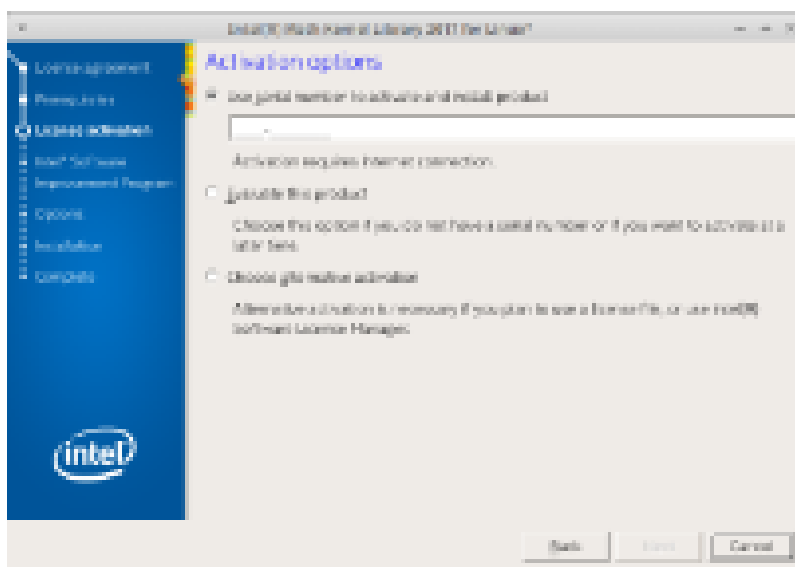


Figura 13. Pantalla de activación del producto

4. Elegir si desea participar en el programa Intel® de mejora de software. Si opta por participar, Intel puede recibir automáticamente información anónima acerca de como usa sus futuros productos de desarrollo de software Intel®. Puede dejar de participar en cualquier momento desde Intel® Software Manager. En la figura 3. Se muestra este paso.




Figura 14. Programa de mejora de Intel®

5. Revisar el resumen de la instalación para ver si las opciones de instalación seleccionadas cumplen sus necesidades. Para cambiar la selección, haga clic en el botón Personalizar de la instalación y proceder a cambiar las siguientes opciones:

Elegir un directorio de instalación alternativo, como se muestra en la figura 4.

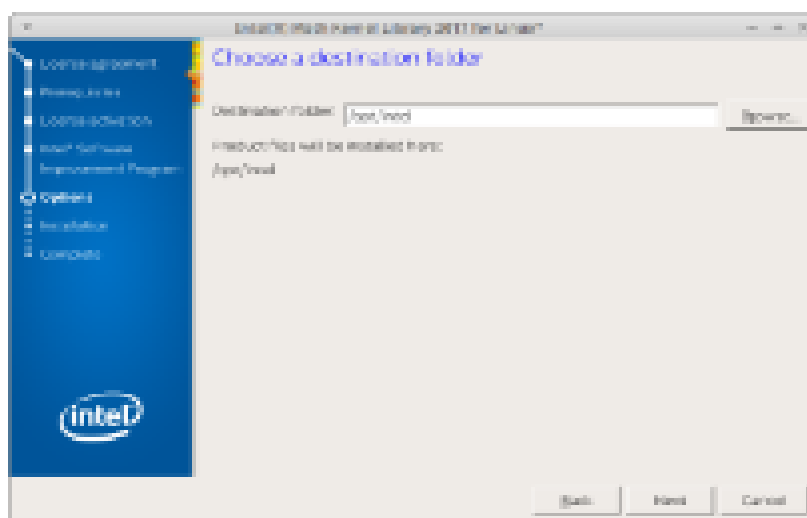


Figura 15. Carpeta de instalación

- Seleccionar la(s) arquitectura(s) para ejecutar sus aplicaciones. De forma predeterminada, IA-32 e Intel® 64 se han seleccionado como arquitectura.
- Seleccionar los componentes que desea instalar, en la figura 5, se selecciona los componentes recomendados para compatibilidad con C/C++ como de FORTRAN.




Figura 16. Componentes del paquete

Para continuar con la instalación, haga clic en el botón Instalar, en la figura 6, se presenta el recuento de las características de instalación.




Figura 17. Recuento de las características seleccionadas para instalar

- Hacer clic en siguiente para iniciar la instalación. Cuando todos los componentes seleccionados estén instalados se muestra la ventana de finalización.



Figura 18. Finalizar la instalación

EIGEN

Eigen es una biblioteca C++ de alto nivel de plantillas para algebra lineal, operaciones de matrices y vectores, transformaciones geométricas, solucionadores numéricos y algoritmos relacionados. Eigen es una biblioteca de código abierto con licencia bajo MPL2 a partir de la versión 3.1.1 las versiones anteriores fueron licenciadas bajo LGPL3+.

INSTALACION EIGEN

Método 1: Instalación sin utilizar CMake: se puede utilizar de inmediato los encabezados en el subdirectorio Eigen/. Para instalar, simplemente copiar el subdirectorio Eigen/ a su ubicación favorita. Si también desea las funciones no admitidas, copiar los archivos del directorio unsupported/.

Método 2: Instalación mediante CMake: llamar al directorio que contiene todos los archivos como "source_dir" (donde esta el archivo INSTALL). Antes de comenzar, cree otro directorio l que se llamara 'build_dir'.

```
1 user@localhost:~$ cd build_dir
2 user@localhost:~$ cmake ../../source_dir
3 root@localhost:~# make install
```

El paso "Make install" puede requerir privilegios de administrador.

Puede ajustarse el destino de la instalación pasando la opción `-DCMAKE_INSTALL_PREFIX=myprefix` a CMake, tal como esta explicado en el mensaje que CMake imprime al final. Para más información consultar en su dirección web.

A.1. Manual de Uso

La aplicación presenta una interfaz muy fácil de utilizar, en las Figuras A.8 y A.9 se muestran las áreas de trabajo y las configuraciones que se permiten hacer en la interfaz.

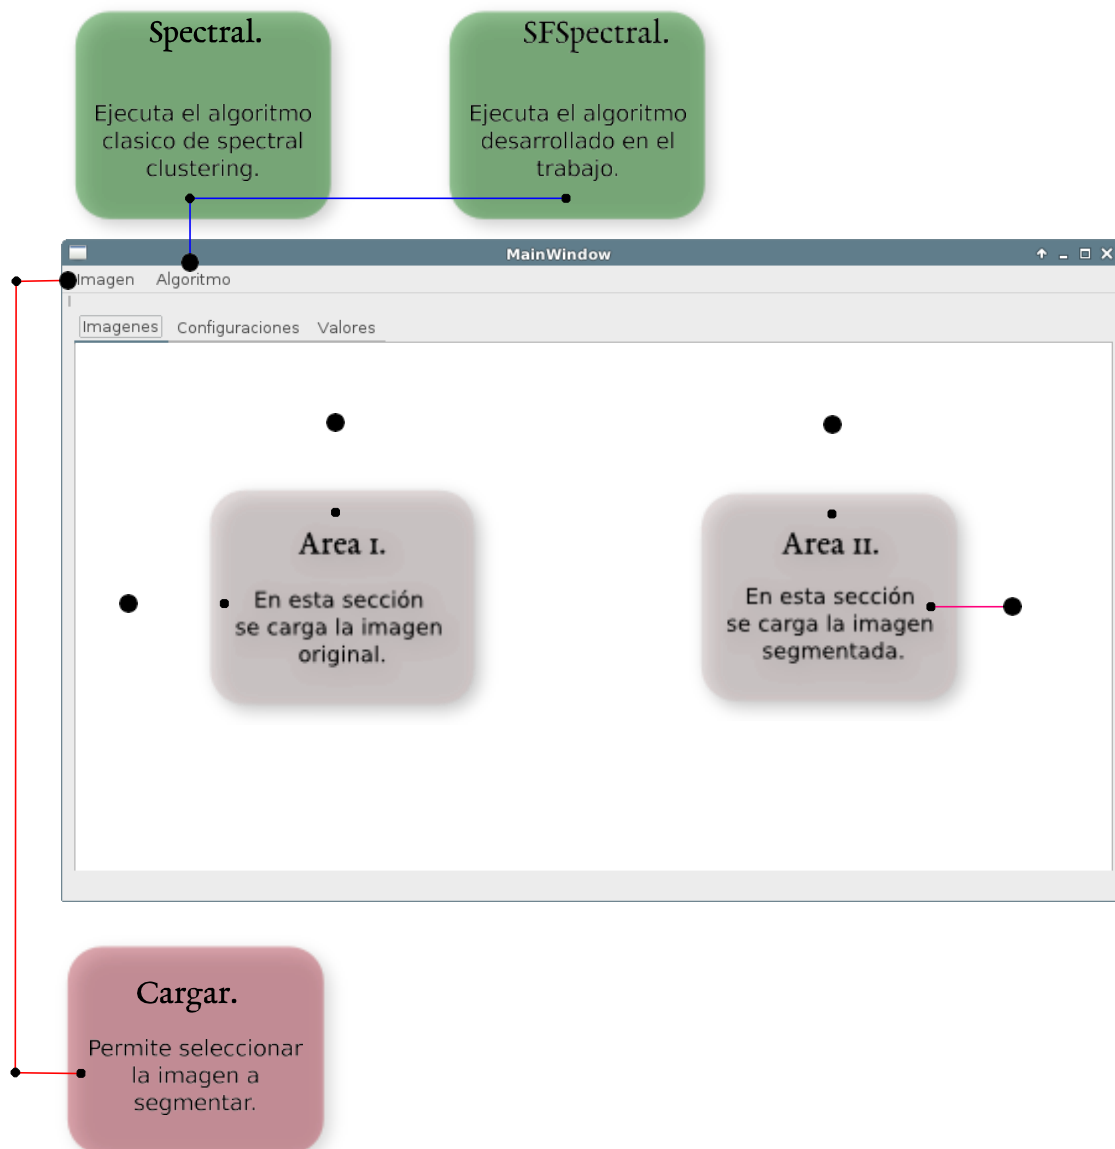


Figura 19. Área de trabajo de la aplicación

En la Figura 19, se muestran las diferentes áreas de trabajo, área donde se carga la imagen original y la imagen segmentada, las acciones de cargar y guardar la imagen a segmentar y la aplicación del algoritmo SC como de SFSC.

Ahora se presenta la Figura 9, en la cual se muestran las posibles configuraciones.




Figura 20. Parámetros de configuración

En la Figura 20, se describen las diferentes posibilidades para los parámetros de configuración de los algoritmos SC y SFSC. Dentro de las configuraciones se encuentra la selección del tipo de imagen (Gris para SC, RGB para SC y SFSC), el tipo de matriz Laplaciana como de la matriz de similitud, la función de distancia, cantidad de vectores propios y el tipo de visualización de la pre-segmentación por SLIC, además se pueden modificar los parámetros de las características anteriormente mencionadas, número de grupos como de súper píxeles, fuzzyness, epsilon, m , sigma, número de vecinos para la similitud y factor de ponderación de la posición.



Universidad Nacional del
Altiplano Puno



Vicerrectorado de
Investigación



Repositorio
Institucional

DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo **HENRY NILTON TITO VALDEZ** identificado(a) con N° DNI: **40200927** en mi condición de egresado(a) de la:

MAESTRÍA EN INFORMÁTICA CON MENCIÓN EN INGENIERÍA DE SOFTWARE

con código de matrícula N° 124322, informo que he elaborado la tesis denominada:

“SEGMENTACIÓN AUTOMÁTICA NO SUPERVISADA DE IMÁGENES MEDIANTE AGRUPAMIENTO ESPECTRAL”.

Es un tema original.


Declaro que el presente trabajo de tesis es elaborado por mi persona y no existe plagio/copia de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno, 07 de Febrero del 2024.



FIRMA (Obligatorio)



Huella



Universidad Nacional del
Altiplano Puno



Vicerrectorado de
Investigación



Repositorio
Institucional

AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo **HENRY NILTON TITO VALDEZ** identificado(a) con N° DNI: **40200927**, en mi condición de egresado(a) del **Programa de Maestría o Doctorado: MAESTRÍA EN INFORMÁTICA CON MENCIÓN EN INGENIERÍA DE SOFTWARE**, informo que he elaborado la tesis denominada:

“SEGMENTACIÓN AUTOMÁTICA NO SUPERVISADA DE IMÁGENES MEDIANTE AGRUPAMIENTO ESPECTRAL”.

para la obtención de **Grado.**

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los “Contenidos”) que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno, 07 de Febrero del 2024.

FIRMA (Obligatorio)



Huella