



Instituto Politécnico Nacional

Centro de Investigación en Computación

**Cómputo granular para clasificación de imágenes con
base en su contexto.**

T E S I S

Que para obtener el grado de:

Maestría en Ciencias de la Computación

P R E S E N T A :

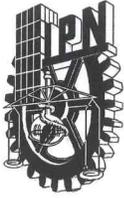
Ing. José Abraham Estrada Hernández

Director de Tesis:

Dr. Herón Molina Lozano

Julio 2016





INSTITUTO POLITÉCNICO NACIONAL SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

ACTA DE REVISIÓN DE TESIS

En la Ciudad de _____ México, _____ siendo las 10:00 horas del día 07 del mes de junio de 2016 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del:

Centro de Investigación en Computación

para examinar la tesis titulada:

“Cómputo granular para clasificación de imágenes con base en su contexto”

Presentada por el alumno:

ESTRADA

Apellido paterno

HERNÁNDEZ

Apellido materno

JOSÉ ABRAHAM

Nombre(s)

Con registro:

A	1	4	0	0	9	0
---	---	---	---	---	---	---

aspirante de: **MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA

Director de Tesis

Dr. Herón Molina Lozano

Dr. Juan Humberto Sossa Azuela

Dr. Víctor Hugo Ponce Ponce

Dra. Elsa Rubio Espino

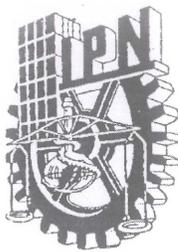
Dr. Ricardo Barrón Fernández

PRESIDENTE DEL COLEGIO DE PROFESORES



INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN
EN COMPUTACIÓN
DIRECCIÓN

Dr. Luis Alfonso de la Cruz



CARTA CESIÓN DE DERECHOS

En la Ciudad de México el día 28 del mes Junio del año 2016, el (la) que suscribe José Abraham Estrada Hernández alumno (a) del Programa de Maestría en Ciencias de la Computación con número de registro A140090, adscrito a Centro de Investigación en Computación, manifiesta que es autor (a) intelectual del presente trabajo de Tesis bajo la dirección del Dr. Herón Molina Lozano y cede los derechos del trabajo intitulado Cómputo granular para clasificación de imágenes con base en su contexto, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección abraham.e@gmail.com. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.


José Abraham Estrada Hernández

Nombre y firma

Resumen

La capacidad compleja de observar y reconocer imágenes por nuestros cerebros aún no ha podido ser lograda por algún sistema computacional con resultados comparables.

Dado que los humanos no podemos reproducir verbalmente como reconocemos las imágenes, es necesario el desarrollo de técnicas y algoritmos para extraer datos de los objetos de nuestro interés y proveer a los sistemas artificiales de la capacidad de reconocimiento.

Así mismo, en años recientes, el cómputo granular como paradigma de procesamiento de información ha aparecido como una tendencia emergente, debido a que se entiende como la manera más cercana a la que nuestro cerebro procesa la información y resuelve problemas, la cual consiste agrupar datos a partir de similitudes entre los mismos para extraer conocimiento útil.

Por lo anterior, se presenta un sistema para la segmentación de imágenes usando cómputo granular, la idea principal es utilizar las similitudes en las vecindades de los datos de entrada (píxeles) para generar asociaciones entre entes individuales, y convertirlos en gránulos de información, con estos gránulos extraer información útil para alimentar un clasificador como una red neuronal artificial para la toma de decisiones.

Abstract

Our brains have a complex capacity to observe and recognize images, which, it's still unmatched by any computational system with comparable results.

Since humans can not express verbally how do we recognize images, it's a necessity the development of techniques and algorithms on the matter, the goal will be to extract the object's data that fits our interests and provide artificial systems with the pattern recognition capability.

Recently, Granular computing has emerged as a new information processing paradigm, whose approach can be seen as the closest way our brain processes information and solves problems, consisting on data grouping based on neighbor similarities to extract useful knowledge.

Because of the above, an image segmentation system is presented which uses granular computing, the main idea is to use the similarities between each input data (pixels) and its neighbors to generate connections between individual elements, and turn them in to information granules, then, with such granules extract meaningful information which is feed into an artificial neural network for classification and decision making.

Agradecimientos

Dedico este trabajo a las personas que me han apoyado para lograr mis objetivos y sueños a lo largo del camino llamado vida, que hemos compartido.

A mi esposa Flor Julieta, que me ha dado todo su amor, apoyo y paciencia para poder terminar este objetivo, que me tomo muchas noches de desvelo, su presencia en mi vida, junto con la de mi hijo Abraham, han sido y serán la inspiración más grande para seguir adelante y dar lo mejor de mí.

A mis padres y hermanos que siempre me han apoyado de manera incondicional, que desde mi primer aliento han estado a mi lado de una forma u otra y cuyo consejo siempre consideraré valioso.

A mi gran amigo y socio Javier Vázquez, que me ha apoyado desde el inicio de este objetivo.

A mi director de tesis, Dr. Herón Molina Lozano, que me brindó su apoyo, consejo y experiencia, aún yendo a contracorriente.

A mis asesores, profesores y compañeros, que con sus aportaciones hicieron más completo mi crecimiento en este centro.

Finalmente, pero no menos importante, quiero agradecer al Instituto Politécnico Nacional, al Centro de Investigación en Computación y al CONACyT por todo el apoyo brindado para la realización de este trabajo.

¡Muchas Gracias!

Índice general

Resumen	I
Abstract	II
Lista de figuras	VI
Lista de tablas	VIII
1. Introducción	2
1.1. Antecedentes	2
1.2. Planteamiento de los problemas a resolver	4
1.3. Justificación	4
1.4. Hipótesis	5
1.5. Objetivos	6
1.5.1. Objetivo General	6
1.5.2. Objetivos Específicos	6
2. Estado del Arte	7
2.1. Del cómputo granular	7
2.2. De la segmentación de imágenes	9
3. Marco Teórico	13
3.1. Cómputo Granular	13
3.1.1. ¿Qué es el cómputo granular?	13
3.1.2. Gránulo de información	13
3.1.3. Caracterización Cuantitativa y Cualitativa.	14
3.1.4. Cómputo con gránulos.	14
3.1.5. Mapeos.	14

3.1.6.	Conversión Granular.	15
3.1.7.	Operadores.	15
3.1.8.	Preservación de propiedades.	15
3.1.9.	Estructura granular jerárquica	16
3.1.10.	Estructuras Granulares	16
3.1.11.	Problemas básicos del cómputo granular	17
3.1.12.	Granulación	18
3.1.13.	Criterio de granulación	18
3.1.14.	Métodos de granulación	19
3.1.15.	Representación / Descripción	19
3.2.	Imágenes	19
3.2.1.	Problemas y retos del procesamiento de imágenes.	20
3.2.2.	Enfoques complementarios	21
3.2.3.	Representación de imágenes	21
3.2.4.	El modelo de color	22
3.2.5.	Espacio de color	22
3.2.6.	El espacio de color HSV	22
3.3.	Reconocimiento de patrones	24
3.3.1.	El vocabulario del reconocimiento de patrones	24
3.3.2.	Las tareas del reconocimiento de patrones.	28
3.3.3.	Clasificación	29
3.3.4.	Agrupamiento (Clustering)	34
3.3.5.	Matriz de confusión, Recuerdo y Precisión	36
4.	Desarrollo	38
4.1.	La idea detrás de todo.	38
4.2.	Proceso general	39
4.3.	Los datos de entrada: Las imágenes	40
4.4.	El sistema granular	41
4.4.1.	Gránulos	42
4.4.2.	Capas de gránulos (Layers)	46
4.4.3.	Jerarquía	47
4.4.4.	Salida del sistema granular.	48
4.5.	Convertidor PDSV a PC	48
4.5.1.	Estructura de un PDSV	48
4.5.2.	Dimensionalidad Variable	49
4.5.3.	Significado Posicional Variable	50
4.5.4.	Aplicabilidad en clasificadores convencionales.	50

4.5.5. Ventajas de los PDSV	51
4.5.6. Construcción y representación conceptual	51
4.6. Clasificación	55
5. Experimentos y Resultados	56
5.1. Del sistema granular	56
5.1.1. Experimento 1	56
5.1.2. Experimento 2	58
5.2. Del sistema de representación conceptual	60
5.2.1. Experimento 1	60
5.3. Del sistema de clasificación	68
5.3.1. Sistemas de clasificación supervisada	68
5.4. De los algoritmos de agrupamiento no supervisado	78
5.4.1. Fuzzy C-Means	78
5.4.2. Possibilistic C-Means	80
5.4.3. Gustafson Kessel	82
5.4.4. Agrupamiento Hiper cónico (Dancing Cones)	84
5.4.5. Sumario de algoritmos no supervisados	86
5.5. Tiempos de ejecución	86
5.6. Discusión	88
6. Conclusiones	90
6.1. Conclusiones	90
6.2. Aportaciones	91
6.3. Limitaciones	91
6.4. Trabajo Futuro	91
Apéndices	93
Apéndice A. Algoritmos de agrupamiento	94
A.1. Algoritmo Fuzzy C-means (FCM)	94
A.2. Algoritmo Possibilistic C-Means (PCM)	95
A.3. Algoritmo Dancing Cones (DC)	95
Bibliografía	96

Índice de figuras

2.1. Medidas teóricas de un conjunto rugoso para un objeto	8
2.2. Modelo de segmentación de imágenes	9
2.3. Resultados de segmentación de imágenes, (de derecha a izquierda: imagen original, imagen real, GrCC, mean shift, K-means, proposed GrCC)	10
3.1. Esquema de color HSV	23
3.2. Tipos de datos en patrones.	26
3.3. Pasos básicos de clasificación.	29
3.4. Paradigma de reconocimiento	30
3.5. Modelo de la neurona perceptron	31
3.6. Arquitectura de una red neuronal de perceptrones multicapa, con dos neuronas de entrada, 2 capas ocultas con 3 y 2 neuronas, y una neurona de salida.	32
4.1. Objetivo a lograr, clasificar imágenes	40
4.2. Detalle del Objetivo a lograr	40
4.3. Componentes de una imagen en espacio de color RGB y HSV	41
4.4. Estructura del sistema granular	42
4.5. gránulo y su relación con el índice de conectividad	44
4.6. Zonas en las que se divide la imagen	46
4.7. Ejemplo de significancia variable.	50
4.8. Construcción de concepto en R2	53
4.9. Construcción de concepto en R3	54
4.10. Nubes de datos	55
5.1. Versiones abstraídas para varias clases, columna1-original, columna2-salida de capa 1, columna 3- salida capa 2 abstraída	57

5.2.	Zonas obtenidas para las muestras anteriores	57
5.3.	Influencia de ϕ en cantidad y tamaño máximo de zonas conec- tadas	59
5.4.	Imágenes usadas para la clase playa	61
5.5.	Imágenes usadas para la clase desierto	62
5.6.	Imágenes usadas para la clase bosque	63
5.7.	Imágenes usadas para la clase de prueba 1 ESCOM	64
5.8.	Imágenes usadas para la clase de prueba 2 CIC interior	65
5.9.	Cúmulos resultantes para varias clases	66
5.10.	Cúmulos resultantes para varias clases en el mismo espacio	67
5.11.	Arquitectura de la red neuronal usada	68
5.12.	Nubes de datos para las clases elegidas	69
5.13.	Salida de neuronas y los patrones aplicados	70
5.14.	Matriz de confusión resultante	71
5.15.	Evolución del error durante entrenamiento	71
5.16.	Nubes de datos para las clases elegidas	72
5.17.	Salida de neuronas y los patrones aplicados	73
5.18.	Matriz de confusión resultante	74
5.19.	Evolución del error durante entrenamiento	74
5.20.	Nubes de datos para las clases elegidas	75
5.21.	Salida de neuronas y los patrones aplicados	76
5.22.	Matriz de confusión resultante	77
5.23.	Evolución del error durante entrenamiento	77
5.24.	Resultados usando Fuzzy C-Means	78
5.25.	Resultados usando Fuzzy C-Means	79
5.26.	Resultados del PC y PE para FCM	79
5.27.	Resultados usando Possibilistic C-Means	80
5.28.	Resultados usando Possibilistic C-Means	81
5.29.	Resultados del PC y PE para PCM	81
5.30.	Resultados usando Gustafson Kessel	82
5.31.	Resultados usando Gustafson Kessel	83
5.32.	Resultados del PC y PE para algoritmo Gustafson Kessel	83
5.33.	Resultados usando conos danzantes	84
5.34.	Resultados usando Conos Danzantes	85
5.35.	Resultados del PC y PE para algoritmo Conos Danzantes	85

Índice de tablas

2.1. Comparativa de trabajos en el estado del arte	12
5.1. ϕ y cantidad de zonas resultantes	58
5.2. ϕ y tamaño de zona máximo encontrado	59
5.3. Resultados de la red neuronal para los patrones introducidos .	71
5.4. Resultados de la red neuronal para los patrones introducidos .	74
5.5. Resultados de la red neuronal para los patrones introducidos .	77
5.6. Comparativa de accuracy para los 4 algoritmos usados	86
5.7. Comparativa de tiempos de ejecución con otros trabajos . . .	87

Introducción

1.1. Antecedentes

En un instante nuestros sentidos, específicamente la vista, percibe información, la cual sin un retraso perceptible es evaluada, analizada y sus contenidos esenciales son reconocidos, esta capacidad compleja de nuestros cerebros aún no ha podido ser lograda por algún sistema computacional con resultados comparables.

Uno de los grandes problemas para lograr un desempeño similar en las máquinas es el hecho de que los humanos no podemos reproducir verbalmente lo que sucede en nuestro cerebro para el reconocimiento de imágenes debido a que esto sucede de manera inconsciente. Lo anterior ha generado la necesidad de desarrollar técnicas y algoritmos para extraer datos de los objetos de nuestro interés y proveer a los sistemas artificiales de la capacidad de reconocimiento.

El reconocimiento de patrones es una disciplina científica y entre uno de sus objetivos está la clasificación de objetos en un número de categorías o clases, para tal efecto, los objetos son abstraídos en imágenes, señales con cierta forma de onda o cualquier tipo de medidas para formar representantes que pueden ser clasificados, nos referiremos a estas representaciones usando el término genérico de patrón.

El reconocimiento de patrones tiene una larga historia aunque hasta antes de 1960 se refería mayoritariamente a resultados en la investigación científica en el área de estadística.

Con el advenimiento de las computadoras se incrementó la demanda de aplicaciones prácticas para el reconocimiento de patrones lo cual en turno genero nuevos requerimientos para más desarrollos teóricos. Así como nuestra sociedad evoluciona desde la etapa industrial a su fase postindustrial, la producción, obtención y manejo de la información han empujado a esta disciplina a un nivel tal, que hoy forma parte integral de las aplicaciones de ingeniería en muchas de las máquinas con sistemas inteligentes construidos para toma de decisiones.

La visión de máquina o visión artificial es un área en la cual el reconocimiento de patrones es de alta importancia, un sistema de visión artificial captura imágenes vía una cámara y las analiza para producir descripciones de lo que fue adquirido, una aplicación típica de un sistema de visión artificial es en la industria de la manufactura ya sea para un sistema de inspección visual automático o para una línea automática de ensamble, por ejemplo en la inspección objetos manufacturados en una banda transportadora moviéndose, estos pasan por la estación de inspección donde la cámara se encuentra y captura imágenes de los mismos.

Las imágenes capturadas tienen que ser analizadas en línea y el sistema de reconocimiento de patrones tiene que clasificar los objetos en la clase “defectuoso” o “no defectuoso”, con este resultado una acción tiene que ser tomada como que el objeto sea rechazado o, que continúe en la banda transportadora, como el ejemplo anterior existen muchos, como la selección de herramientas en una línea de ensamble o un sistema de reconocimiento de caracteres, entre muchos otros.

En la parte concerniente al procesamiento de imágenes antes de ser alimentadas al clasificador se deben de aplicar algoritmos para obtener rasgos, o propiedades contenidas en las mismas, una propiedad que es de especial interés son las zonas o regiones conectadas dentro de la imagen.

Actualmente existen algoritmos que escanean pixel a pixel las imágenes conectadas ya sea antes o después de hacer binarizado a las mismas para obtener zonas. En este estudio usaremos un enfoque distinto tanto a la binarización como a la generación de zonas, para lo cual usaremos gránulos de información para obtener zonas conectadas en un contexto abstraído de la imagen.

1.2. Planteamiento de los problemas a resolver

El problema se atacará es la clasificación supervisada de imágenes cuyo contenido serán escenas o paisajes, específicamente, bosques, playas y desiertos, usando técnicas de cómputo granular.

1.3. Justificación

Como se mencionó, la necesidad de dar a las máquinas la capacidad de reconocer patrones es importante, dado que el reconocimiento de patrones ha permeado en muchísimas áreas del desarrollo humano, su aplicación en imágenes es un reto porque la información contenida puede tener un amplio abanico de significados.

Existen técnicas que permiten la segmentación de imágenes, el trabajo necesario involucra una serie de operaciones de filtrado y realce que producen resultados que son útiles para ser clasificados.

Ya dentro del ámbito del segmentado el proceso de umbralado se ve altamente influenciado por los niveles de iluminación presentes en la imagen, lo cual genera una dependencia de la calidad del resultado, y la calidad de la iluminación de la escena capturada.

Por lo anterior, si binarizamos la imagen basados en un nivel específico de intensidad (nivel único, Método de Otsu)[11] veremos que solamente ciertas zonas serán correctamente umbradas mientras que las zonas que tengan valores de intensidad muy alejados al seleccionado pero que contienen información perteneciente a una zona de interés y por lo tanto relevante, se perderán, esta misma situación se repite aunque de menor manera usando otros métodos que consideran otras técnicas[8].

El computo granular es un paradigma enfocado al conocimiento y al hacer extensivo este paradigma a los sistemas de información se les puede dotar de capacidades superiores para percibir el entorno que los rodea.

1.4. Hipótesis

Mediante la elección del formato HSV (*Hue, Saturation, Value*, por sus siglas en inglés.) para representación de imágenes que usa tres coordenadas y condensa la información de color en una sola de ellas, la correspondiente al matiz (Hue), obtendremos un aislamiento de valores de color e iluminación, es decir si una imagen es capturada con iluminación (brillo) no uniforme, la extracción de las coordenadas de color tendrá un impacto reducido debido a esto.

El procesamiento usando cómputo granular nos permitirá asociar elementos de información de la imagen (píxeles) usando sus valores de color, lo cual nos proporciona ayuda adicional para no depender de valores únicos o globales al momento de umbralar la imagen, esto redundará en menor pérdida de información relevante debido a zonas mal iluminadas.

En resumen, con la representación de la imagen en el espacio de color HSB y el procesamiento de la misma usando cómputo granular, podemos enfrentar los problemas de pérdida de información al umbralar desde una perspectiva diferente que nos permitirá obtener zonas conectadas de mejor calidad en un nivel de abstracción distinto.

A través de la suma de zonas resultantes podremos obtener un vector representante de la imagen, que será el elemento constituyente de nubes de datos para su posterior clasificación.

1.5. Objetivos

1.5.1. Objetivo General

Describir y desarrollar un sistema de información (software) para clasificar imágenes usando técnicas de cómputo granular y sistemas de clasificación.

1.5.2. Objetivos Específicos

Diseñar e implementar un elemento de procesamiento granular (gránulo) que tiene relación con sus vecinos inmediatos y capas superiores e inferiores de la estructura general.

Generar una estructura multicapa para alojar los gránulos de información creados con antelación. La cual permitirá mapear la imagen de entrada a la capa base, y comunicar el resultado a las capas superiores.

Diseñar e implementar un algoritmo distribuido para obtener zonas conectadas en una versión de grano grueso de una imagen.

Generar e implementar un sistema que permita escalar los patrones generados en la segmentación para cambiar su dimensionalidad de variable a fija.

Usar un algoritmo para clasificar los patrones obtenidos en la segmentación.

Estado del Arte

2.1. Del cómputo granular

Witold Pedrycz, establece que el cómputo granular es un paradigma orientado al "conocimiento", mientras que el cómputo numérico está orientado a los "datos". Aunque existen algunos marcos de referencia existentes bajo nombres como: conjuntos difusos, análisis de intervalos, conjuntos rugosos y probabilidad, la idea de Pedrycz es proponer los fundamentos del cómputo granular visto como un nuevo paradigma unificado para el procesamiento de gránulos de información.

Se ha definido una agenda de investigación principal en este ámbito que abarca[15]:

- El diseño y construcción de gránulos de información
- Definición del nivel de granularidad o resolución.
- Desarrollo de técnicas de codificación y decodificación.

Existen estudios que involucran cómputo granular al nivel de lo que son los conjuntos rugosos que son aplicados una vez que la información ha sido tratada y procesada, y que los vectores de rasgos extraídos de los objetos de estudio ya se tienen capturados.

Siendo la teoría de conjuntos rugosos una herramienta matemática popular para el cómputo granular, el enfoque de dicha teoría está en la ambigüedad causada por la limitada discernibilidad de los objetos en el dominio o universo de discurso. Los gránulos son formados de objetos y aglutinados por la discernibilidad limitada entre ellos, es decir, si no son distinguibles entonces

son similares. Un conjunto rugoso representa a un conjunto en términos de sus aproximaciones superior e inferior.

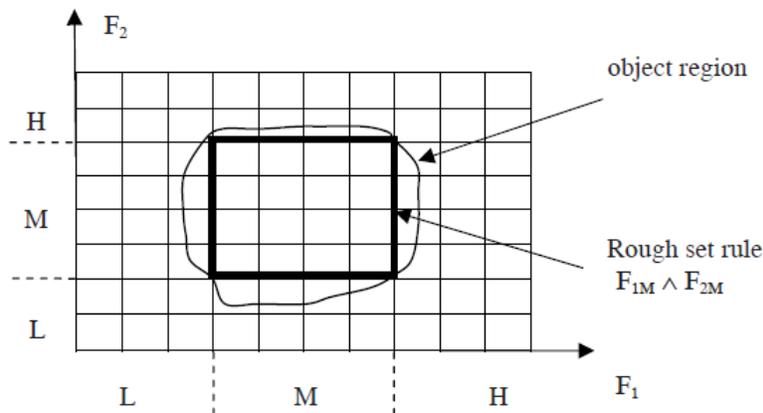


Figura 2.1: Medidas teóricas de un conjunto rugoso para un objeto

La aproximación inferior contiene gránulos que pertenecen completamente al conjunto (de la imagen M), y la aproximación superior contiene los gránulos que parcial o completamente pertenecen al conjunto (fuera de M que contienen frontera del objeto). Las técnicas basadas en conjuntos rugosos han sido usadas en campos como el reconocimiento de patrones, procesamiento de imágenes, minería de datos y en el proceso de descubrimiento de conocimiento en grandes bases de datos. Recientemente se ha encontrado un uso extensivo en la reducción de dimensionalidad y codificación del conocimiento, particularmente cuando la incertidumbre es debido a la granularidad en dominio o universo de discurso, además de que se ha mostrado como una herramienta efectiva en el aprendizaje de máquina para el diseño de clasificadores conjuntos.[12]

Pedrycz sostiene que cuando los gránulos son aglutinados a varias escalas se generan gránulos de orden superior (caracterizados por grados de membresía, por ejemplo conjuntos difusos tipo 2) y de tipo superior (es decir las construcciones del universo de discurso están formadas por gránulos en lugar de elementos aislados), esto a su vez da lugar a agrupamientos granulares jerárquicos, dichos sistemas jerárquicos exhiben capas conceptuales de abstracción aumentada.

Lo anterior hace patente que existen actualmente métodos o algoritmos aplicables a sistemas granulares basados en capas[16].

Existen ciertas medidas y valores específicos que denotan el número de clusters que un sistema granular regresa se considera que para tener un buen nivel de detalle, interpretación y semántica de los datos este número es de 7 ± 2 [14].

Siendo el cómputo granular un estudio multidisciplinario e interdisciplinario, concierne al cómputo inspirado en humanos y la resolución de problemas que ha sido emergente desde hace pocos años, se tienen tareas pendientes como son: la unificación de términos usados para una mejor comunicación de ideas en el tema, cambiar de un enfoque orientado a las máquinas a uno inspirado en humanos para el estudio del cerebro humano y la inteligencia natural, moverse más allá de los conjuntos difusos, y los conjuntos rugosos para hacer del cómputo granular una teoría más general para la resolución de problemas[21].

2.2. De la segmentación de imágenes

Existen actualmente estudios para la segmentación de imágenes basados en Granular Reflex Fuzzy Min-Max Neural Networks (GrRFMN) que consisten en un mecanismo inspirado en cómo el cerebro humano maneja los traslapes entre clases, aunque estos se apoyan fuertemente en la ayuda del conocimiento humano dado que son sistemas supervisados, es de notar que el cómputo granular es adecuado en la segmentación de imágenes de color acorde a los resultados mostrados a continuación, donde vemos la imagen original, las imágenes semilla que se usaron para entrenar la red y los resultados que se obtienen con gránulos en dos resoluciones distintas[9].

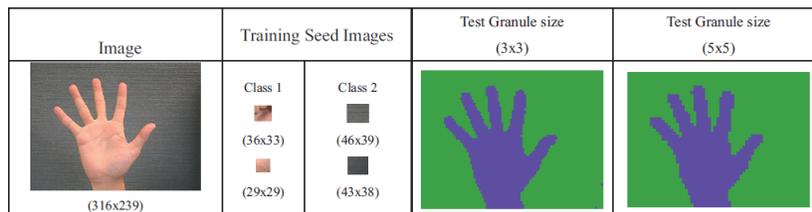


Figura 2.2: Modelo de segmentación de imágenes

La segmentación de imágenes a color ha sido un tema significativo y difícil en el campo del procesamiento digital de imágenes. Debido a la complejidad de las imágenes a color, los resultados de la segmentación tradicional usando agrupamiento basado en cómputo granular (GrCC) son indeseables, sin embargo, nuevas mejoras basadas en cómputo granular (GrC) para las imágenes a color han sido propuestas, esto a través del uso de filtros que analizan la información, de tal manera que la información de textura y de color son combinadas y entonces se usa el cómputo granular para agrupar cada pixel. Aún más, para obtener el resultado de segmentación, una imagen es reconstruida por medio de la información del cluster de pixeles. Para una evaluación del método de segmentación objetiva, los resultados de este método de segmentación son comparados con imágenes reales.

Los resultados muestran que el método indicado produjo una alta exactitud (92.51 %) en la segmentación de imágenes por color, sin embargo, aún hay problemas por resolver como son el hecho de que el umbral usado en cada imagen es diferente, lo cual sería más conveniente y efectivo si dicho umbral fuera auto-adaptivo.[13]

Los resultados se muestran a continuación.

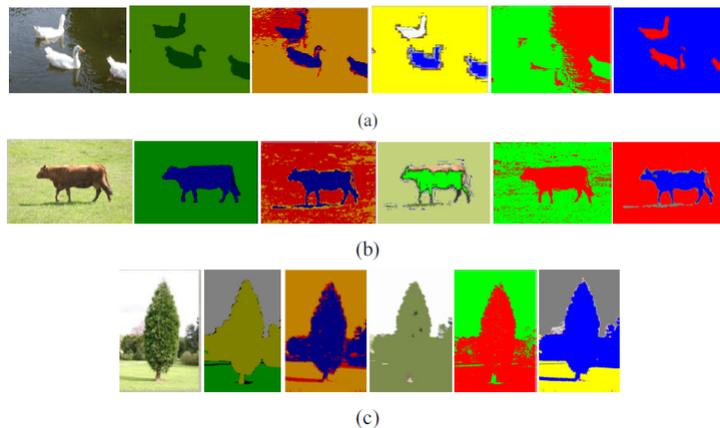


Figura 2.3: Resultados de segmentación de imágenes, (de derecha a izquierda: imagen original, imagen real, GrCC, mean shift, K-means, proposed GrCC)

Aunque existen diversas métricas para obtener la similitud entre vectores, la distancia Euclidiana es de las más utilizadas para calcular la similitud

entre dos imágenes después de haber sido sintetizadas a las funciones de atributos que las definen.[3]

El uso de gránulos de información acompañado de otras herramientas ha sido utilizado para mejorar la respuesta de ciertos sistemas a nivel de clasificación, tal es el caso de los detectores de peatones, donde se evalúa el gradiente de pequeños rectángulos para obtener las diferencias de nivel por región (gránulo) y los resultados que pudieron obtenerse están en el 92 % de tasa de detección.[1]

Así mismo, los sistemas granulares se han aplicado a tareas visuales, donde las similitudes visuales de una imagen dan origen a una estructura columnar que tiene una organización granular y jerárquica similar a la de nuestro cerebro, para poder así remover la neblina de imágenes demostrando así que la lógica difusa, y el aprendizaje de máquina, pueden hibridarse y cooperar fácilmente para diseñar un sistema granular.[6]

Otro ejemplo de aplicación a tareas visuales se da en la segmentación mamografías usando medidas de entropía rugosa para diagnosticar el cáncer de seno en etapas tempranas con resultados de clasificación que rondan el 83 % de exactitud.[18]

En algunos casos se realiza la segmentación de imágenes usando cómputo granular con algoritmos específicos de aglomeración de gránulos con rugosidad, siendo está una medida importante de las condiciones ambiguas de los objetos en la teoría de conjuntos rugosos, se usa como atributo de los gránulos para determinar su heterogeneidad y ser comparada con cierto umbral.[4]

Como conclusión, se observa que aun cuando existen aportes en segmentación de imágenes usando cómputo granular para posteriormente clasificar, los enfoques utilizados requieren ya sea de: medidas complejas de la información contenida o de redes neuronales complejas para lograr el entrenamiento y clasificación. Dado lo anterior, se entiende que deben encontrarse esquemas alternativos para optimizar los resultados y/o la cantidad de recursos o tiempo para lograrlos.

La información anteriormente presentada se resume en la siguiente tabla donde tenemos los aspectos relevantes de cada trabajo:

Título	Pre procesamiento	Hace reconstrucción	Variable de similitud definida por el usuario	Multi-capas	Exactitud (%)	Valor de similitud único	Multi-clase	Generación de la variable granular	Principio de conectividad
Using GrCC for color image segmentation based on the combination of color and texture.	S	S	S	N	95.8	N	N	Función trigonométrica	Umbral
Mammogram image segmentation using granular computing based on rough entropy	S	N	N	N	83.3	N	N	Entropía Rugosa (Función logarítmica)	Umbral
Pedestrian detection using histograms of oriented gradients of granule feature.	N	N	N	N	92	N	N	Función trigonométrica inversa	Votación
Supervised colour image segmentation using granular reflex fuzzy min-max neural network	N	N	N	N	N.A.	N	S	Función de activación compleja	Arg. Max.

Tabla 2.1: Comparativa de trabajos en el estado del arte

Marco Teórico

3.1. Cómputo Granular

3.1.1. ¿Qué es el cómputo granular?

El ser humano es un sistema de procesamiento granular muy sofisticado, con la habilidad de cambiar la resolución o el contexto en el cual está procesando la información percibida, todo esto para adaptarse a las necesidades de un problema dado, por ejemplo, podemos distinguir entre el bosque y un árbol dependiendo de cuál sea el contexto.

De la misma manera, el cómputo granular puede entenderse como un paradigma para el procesamiento de la información, que consiste en agrupar la información basado en las similitudes presentes en los datos de estudio, todo esto con el objetivo de extraer conocimiento de los mismos.

Una característica muy importante de dicho paradigma es que la resolución o tamaño de los gránulos donde se encontrará información significativa de los datos es variable.

3.1.2. Gránulo de información

Consideraremos un gránulo de información a un elemento que aglomera varios datos y realiza operaciones sobre los mismos, para definir así su conectividad con otros gránulos.

Este elemento es una de las numerosas partículas que forman una unidad más grande, colectivamente, estos proveen una representación de la unidad

con respecto a un nivel específico de granularidad.

El tamaño de un gránulo es considerado como una propiedad básica. Intuitivamente, el tamaño puede ser interpretado como el grado de abstracción, resolución o detalle. Las conexiones y relaciones entre gránulos pueden ser representadas por relaciones binarias. Se pueden definir operaciones entre ellos para combinar varios gránulos en uno nuevo o descomponer un gránulo en varios más, siempre cuidando que las operaciones sean consistentes con las relaciones binarias entre ellos.

3.1.3. Caracterización Cuantitativa y Cualitativa.

Se pueden asociar medidas cuantitativas a los tres componentes esenciales del paradigma granular: gránulos, vistas granuladas (también denominadas niveles de abstracción) y jerarquías. Las medidas deben reflejar y ser consistentes con las tres estructuras, la estructura interna de un gránulo, la estructura colectiva de una vista granulada, y la estructura general de una jerarquía.

3.1.4. Cómputo con gránulos.

Computar y razonar con gránulos explora los tres tipos de estructuras. Estas pueden ser estudiadas desde las perspectivas semánticas y algorítmicas, para lo cual es necesario diseñar e interpretar varios métodos basados en la interpretación de los gránulos y las relaciones entre gránulos, así como para definir e interpretar las operaciones de cómputo granular.

3.1.5. Mapeos.

Las conexiones entre diferentes niveles de granulaciones pueden ser descritas como mapeos. En cada nivel de la jerarquía, un problema es presentado con respecto a la granularidad del nivel. El mapeo enlaza diferentes representaciones del mismo problema a diferentes niveles de detalle. En general, uno puede clasificar y estudiar diferentes tipos de granulaciones al enfocarse en las propiedades de los mapeos.

3.1.6. Conversión Granular.

Considerando que una vista es un nivel de abstracción de un problema, una tarea básica del cómputo granular es cambiar las vistas con respecto a los diferentes niveles de granularidad. Conforme nos movemos de un nivel de detalle a otro, es necesario convertir la representación de un problema de manera acorde. Movernos a una vista más detallada puede revelar información que de otra manera no es visible, y movernos a una vista más simple puede mejorar el entendimiento a alto nivel al omitir detalles irrelevantes del problema.

3.1.7. Operadores.

Los operadores pueden definir precisamente la conversión de granularidad en diferentes niveles y sirven como los elementos básicos de construcción del cómputo granular. Existen al menos dos tipos de operadores que pueden ser definidos. Un tipo trata con el cambio de granularidad de fina a gruesa. Una característica de dicho operador es que descartará ciertos detalles, lo que hace que objetos distintos no sean posteriormente diferenciables. Dependiendo del contexto, muchas interpretaciones y definiciones están disponibles, tales como: abstracción, simplificación, generalización, engrosamiento, alejamiento (*zoom-out*), entre otras.

El otro tipo trata con el cambio de una granularidad gruesa a una fina. Una característica de dicho operador es que proveerá más detalles, tal que un grupo de objetos puedan ser clasificados más adelante, este puede ser definido e interpretado como: articulado, especificado, expansión, refinamiento, acercamiento (*zoom-in*), entre otros.

3.1.8. Preservación de propiedades.

La granulación permite diferentes representaciones del mismo problema en diferentes niveles de detalle. Es por lo tanto natural que el problema debe ser consistentemente representado. La granulación y sus métodos de cómputo asociados tienen significado solamente si preservan ciertas propiedades deseadas.

3.1.9. Estructura granular jerárquica

Los gránulos en diferentes niveles están enlazados por relaciones de orden y operaciones entre gránulos. Las relaciones de orden entre gránulos pueden ser extendidos a vistas (niveles de abstracción) granulados. Un nivel de abstracción está arriba de otro nivel si cada gránulo en el nivel base está ordenado después de un gránulo en el nivel siguiente, bajo la relación de orden. El ordenamiento de los niveles puede ser descrito bajo la noción de jerarquía.

La teoría de jerarquías provee un marco multiniveles basado en niveles. Matemáticamente, una jerarquía puede ser vista como un conjunto parcialmente ordenado. Para el estudio del cómputo granular, los elementos de un conjunto ordenado son interpretados como niveles jerárquicos o vistas granuladas. El ordenamiento de niveles en una jerarquía está basado en criterios relacionados a las relaciones de orden en los gránulos.

Un nivel más alto puede proveer una restricción y/o contexto de un nivel más bajo, y puede contener o estar hecho de niveles más bajos. Dependiendo del contexto, una jerarquía podría consistir de niveles de interpretación, niveles de abstracción, niveles de organización, niveles de observación y niveles de detalle. Una jerarquía representa relaciones entre diferentes vistas granuladas, y explícitamente muestra la estructura de granulación.

Un gránulo en un nivel más alto puede ser descompuesto en muchos gránulos de un nivel más bajo, y de la misma manera varios gránulos en un nivel inferior pueden ser combinados para formar un gránulo en un nivel más alto. Un gránulo en un nivel más bajo puede ser una descripción más detallada de un gránulo en un nivel más alto con información agregada. En el otro sentido, un gránulo en un nivel más alto es una descripción de grano grueso de un gránulo en un nivel inferior por omitir detalles irrelevantes.

3.1.10. Estructuras Granulares

Con la introducción de los componentes señalados, podemos examinar los 3 tipos de estructuras para modelar sus interacciones, las cuales son:

- La estructura interna de un gránulo.
- La estructura colectiva de todos los gránulos.

- La estructura general de todos los niveles.

Aunque un gránulo es normalmente considerado como un todo en lugar de muchos sub-gránulos en un nivel en específico, su estructura interna debe ser examinada, la cual provee una descripción propia, interpretación y caracterización del gránulo. Un gránulo puede tener una estructura compleja en sí misma, por ejemplo, la estructura de un gránulo puede ser una jerarquía consistente en varios niveles. Dicha estructura interna resulta útil en el establecimiento de relaciones entre gránulos en niveles distintos.

Todos los gránulos en un nivel pueden colectivamente mostrar cierta estructura. Esta es la estructura interna de una vista granulada. “Los gránulos en cierto nivel, sin embargo, pueden ser relativamente independientes y, estar relacionados sólo hasta cierto grado. Esto proviene del hecho de que en conjunto forman una vista granulada”. La estructura interna de un nivel es solamente significativa si todos los gránulos de cierto nivel son considerados en conjunto.

Una jerarquía representa la estructura general de todos los niveles. En una jerarquía, ambas, la estructura interna del gránulo y la estructura interna de una vista granulada son reflejos, hasta cierto grado de las relaciones de orden existentes. En una jerarquía, ningún par de vistas granuladas pueden ser comparadas con base en relaciones de orden. En el caso especial, la jerarquía es un árbol.

3.1.11. Problemas básicos del cómputo granular

El cómputo granular puede ser estudiado en dos ámbitos principales: la granulación y el cómputo, donde el primero trata con la construcción, interpretación y representación de los tres componentes básicos, y el último trata con el cómputo y razonamiento con los gránulos y las estructuras granulares.

Los estudios del cómputo cubren dos perspectivas, la algorítmica y la semántica. El estudio algorítmico concierne a los procedimientos para construir gránulos, y el cómputo relacionado, y el estudio semántico concierne a la interpretación y el significado físico de varios algoritmos. Los resultados del estudio semántico pueden proveer no sólo interpretaciones y justificaciones para un modelo de cómputo granular particular, sino también guías que

previenen posibles usos inadecuados del modelo. Los resultados del estudio algorítmico pueden conducir a métodos, y herramientas de cómputo granular eficientes y efectivos.

3.1.12. Granulación

La granulación envuelve la construcción de los tres componentes básicos, gránulos, vistas y jerarquías granuladas.

Dos operaciones básicas son: la descomposición *TOP-DOWN* de gránulos grandes a pequeños, y la combinación *BOTTOM-UP* de gránulos pequeños en más grandes.

La noción de granulación puede ser estudiada en varios contextos, La granulación de un problema, una teoría, o un universo, particularmente la semántica de la granulación, es dependiente del dominio y la aplicación. Aun así, es posible identificar algunos elementos independientes del dominio. Por claridad, algunos de estos problemas pueden ser discutidos desde la perspectiva de la teoría de conjuntos.

Desde la perspectiva de la teoría de conjuntos, un gránulo puede ser visto como un subconjunto del universo el cual puede ser difuso o entero. Una familia de gránulos conteniendo a cada objeto en el universo es llamada: vista granulada del universo. Una vista granulada puede consistir de una familia de gránulos ya sean disjuntos o traslapados. Existen muchas vistas granuladas del mismo universo. Vistas distintas del universo pueden estar enlazadas, y una jerarquía de vistas granuladas puede ser entonces establecida.

3.1.13. Criterio de granulación

Un criterio de granulación trata con los problemas semánticos, y responde a la pregunta de por qué dos objetos son puestos en el mismo gránulo. Es de dominio específico y se fundamenta en el conocimiento disponible. En muchas situaciones, los objetos son agrupados basados en sus relaciones, tales como la indistinguibilidad, similitud, proximidad o funcionalidad. Es necesario construir modelos para proveer interpretaciones tanto semánticas como operacionales de dichas nociones. Estos modelos nos permitirán definir las nociones en cuestión de manera formal y precisa para estudiar de manera sistemática los significados de los criterios de granulación.

3.1.14. Métodos de granulación

Desde el aspecto algorítmico, un método de granulación responde al problema de cómo poner dos objetos en un mismo gránulo. Para lo cual es necesario desarrollar algoritmos para construir gránulos y vistas granuladas eficientemente basadas en un criterio de granulación específico.

3.1.15. Representación / Descripción

El siguiente problema es la interpretación de los resultados del método de granulación (por ejemplo las estructuras granulares). Una vez construido es necesario describir, nombrar y etiquetar los gránulos usando cierto lenguaje. Podríamos asignar un nombre a un gránulo tal que un elemento en el gránulo es una instancia de la categoría nombrada. O se podría proveer una descripción formal de objetos en el mismo gránulo. O incluso tomando varias representaciones de gránulos, uno puede obtener la representación general de una vista granulada[22].

3.2. Imágenes

Dado que en esta tesis la materia prima para formar los patrones son imágenes, procederemos a dar un preámbulo general del tema.

Sea una imagen una representación visual que representa a un objeto real o imaginario, puede extenderse como concepto a otros tipos de percepción. Específicamente para la representación visual esta puede llevarse a cabo mediante técnicas diversas como: dibujo, pintura, fotografía o video, conforme la tecnología ha evolucionado la importancia que tienen las imágenes digitales y la información que nos proveen se ha vuelto de suma importancia.

Para ser útil y proveer información relevante una imagen debe ser sometida a una serie de pasos que en general se conocen como procesamiento de imágenes, el cual tiene aplicación en muchas áreas, por solo nombrar un ejemplo, la tecnología de materiales está evolucionando desde los materiales descubiertos en la naturaleza a los que son predichos y diseñados, los materiales permean en todas las áreas imaginables, y aunque no es su aplicación final, el procesamiento de imágenes está tomando parte en esta evolución, aún más, con los incrementos de precisión en la instrumentación que nos

ha llevado directamente a la observación de fenómenos en la escala del sub-Angstrom, evolucionando en escalas de tiempo que rondan los picosegundos, los flujos de datos actuales requieren un tremendo esfuerzo de la comunidad del procesamiento de imágenes.

Dado que al igual que en el área de materiales como en muchas otras, el objetivo último del procesamiento de imágenes es proveer eslabones fuertes a procesos experimentales buscando predecir y mejorar resultados de forma rápida y precisa.

3.2.1. Problemas y retos del procesamiento de imágenes.

Se puede definir un camino relativamente estándar para el procesamiento de imágenes que incluye alguna de las siguientes etapas.

Adquisición de imagen.

Dependiendo de la resolución de nuestro interés diferentes instrumentos pueden ser usados, por ejemplo microscopios electrónicos, tomografías de rayos X, cámaras fotográficas, telescopios incluso nuestros celulares.

Realzado y filtrado

Este paso se relaciona con la mejora de la imagen con respecto al nivel de ruido o desde un punto de vista de homogeneidad. El principal interés lo tienen las técnicas de filtrado de ruido permitiendo sólo modificaciones mínimas a las estructuras o contenidos de interés.

Segmentación.

Este paso que acompaña la reducción de dimensionalidad, clasificación y ajuste de modelos, simplifica imágenes ricas con unos cuantos componentes o intensidades significativas. Con el objeto de recuperar los bordes de interés. Cuando el color o nivel de intensidad están directamente relacionados con las propiedades del objeto Los métodos basados en histogramas globales son complementados con la segmentación basada en criterios, Esta combinación permite la eliminación de elementos que no son de nuestro interés. Para imágenes cuya intensidad está directamente menos relacionada a las propiedades

de interés, la extracción de morfologías locales o contornos puede ser realizada usando procedimientos de optimización global y/o operaciones matemáticas morfológicas.

Análisis

Las estructuras de imágenes pueden ser descritas sin una segmentación explícita de los objetos de interés usando representaciones de multiescala basadas en descomposiciones morfológicas, donde una vez simplificados los objetos de interés pueden ser caracterizados por números, formas o distribuciones espaciales entre otros, junto con el uso de alguna función de distancia asociada se obtendrán las fuentes principales para los algoritmos.

Multimodalidad

Se relaciona con la regularización de la imagen y segmentación, de imágenes multi-modales/multicanal/multiescala adquiridas de las mismas muestras, para el manejo de las mismas es necesario hacer pre procesamiento, registro, filtrado y fusión de imágenes. De manera adicional para extraer información relevante de grupos de datos complejos es útil aplicar técnicas de reducción de dimensionalidad.

3.2.2. Enfoques complementarios

Adicional a lo anterior algunas veces la segmentación y el análisis son fusionados, y llamados “enfoques por textura”, estos métodos se fundamentan en la extracción de características de la imagen sin recurrir a una separación de objetos excesivamente precisa o individual[7].

3.2.3. Representación de imágenes

Cuando hablamos de imágenes digitales que se almacenan en medios electrónicos, la forma de representarlas es a través de secuencias de ceros y unos conformando bytes de información, esta información representa números enteros o decimales, dependiendo de la precisión requerida. La imagen estará compuesta de matrices de datos cuyo tamaño dependerá de la resolución en la que fueron capturadas, cada matriz está asociada a un atributo del espacio de color con el que la imagen está codificada.

3.2.4. El modelo de color

El modelo de color es un modelo matemático abstracto que describe la manera en que los colores pueden ser representados como tuplas de números, típicamente de 3 ó 4 valores o componentes de color. Cuando este modelo está asociado a una descripción precisa de como los componentes tienen que ser interpretados (condiciones de vista, etc.), el conjunto de colores resultante es llamado un espacio de color.

3.2.5. Espacio de color

Un espacio de color es una organización específica de colores en combinación con un perfil de dispositivo físico que permite representaciones reproducibles de color, cuando se define un espacio de color el estándar de referencia común es el CIELAB o CIEXYZ, los cuales están específicamente diseñados para ajustarse a todos los colores que la persona promedio puede ver.

3.2.6. El espacio de color HSV

El espacio de color HSV (del inglés *HUE*, *SATURARION* and *VALUE*, matiz, saturación y valor), definido por estas componentes fue creado en 1978 por Alvy Ray Smith. Se trata de una transformación no lineal del espacio de color RGB.

En él, el matiz se representa por una región circular; una región triangular separada, puede ser usada para representar la saturación y el valor del color (ver fig. 3.1) Normalmente, el eje horizontal del triángulo denota la saturación, mientras que el eje vertical corresponde al valor del color. De este modo un color puede ser elegido al tomar primero el matiz de una región circular, y después seleccionar la saturación y el valor del color deseados de la región triangular.

Se representa como un grado de ángulo cuyos valores posibles van de 0° a 360° (aunque para algunas aplicaciones se normalizan del 0 al 100 %). Cada valor corresponde a un color. Ejemplos: 0° es rojo, 60° es amarillo y 120° es verde.

Esta transformación permite saber los tonos de matices de colores puros que contienen alguna cantidad (o ninguna) de los colores R, G y B. Para el color blanco se puede poner cualquier color y saturación, siempre que se establezca el valor (de luminosidad) máximo. Asimismo, para el color negro se puede poner cualquier color y saturación, siempre que se ponga un valor de 0. [19]

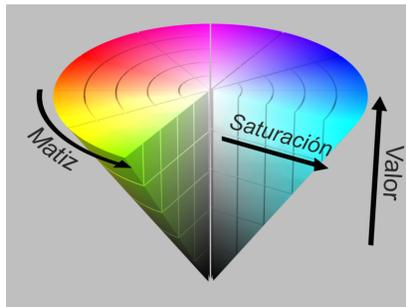


Figura 3.1: Esquema de color HSV

Saturación

Se representa como la distancia al eje de brillo negro-blanco. Los valores posibles van del 0 al 100 %. A este parámetro también se le suele llamar "pureza", por la analogía con la pureza de excitación y la pureza colorimétrica de la colorimetría. Cuanto menor sea la saturación de un color, mayor tonalidad grisácea habrá y más decolorado estará. Por eso, es útil definir la insaturación como la inversa cualitativa de la saturación.

Valor

Representa la altura en el eje blanco-negro. Los valores posibles van del 0 al 100 %. 0 % siempre es negro. Dependiendo de la saturación, 100 % podría ser blanco o un color más o menos saturado.

3.3. Reconocimiento de patrones

Siendo el objetivo la clasificación de imágenes, es natural abordar el reconocimiento de patrones como la disciplina en la que está inmerso este mismo.

3.3.1. El vocabulario del reconocimiento de patrones

Estos son algunos de los conceptos que encontraremos en el ámbito del reconocimiento de patrones.

Patrones y Atributos

En la literatura del reconocimiento de patrones, diferentes palabras pueden ser usadas para expresar el mismo concepto. Por ejemplo, dada una base de datos que contenga varios registros, los términos: punto de datos, patrón, observación, objeto, individuo, elemento y tupla entre otros, son todos usados para denotar un único elemento de datos. En esta tesis usaremos el término PATRÓN para denotar a un registro único. También para un PATRÓN de alta dimensionalidad usaremos las palabras: variable, atributo o característica para denotar un componente escalar individual perteneciente a dicho patrón.

Matemáticamente, un conjunto de datos con n objetos, cada uno de los cuales está descrito por d atributos, es denotado por $D = x_1, x_2, \dots, x_n$, donde $x_i = (x_{i1}, x_{i2}, \dots, x_{id})^T$ es un vector denotando el i -ésimo objeto y x_{ij} es un escalar denotando el j -ésimo componente o atributo de x_i . El número de atributos d es también llamado la dimensionalidad del conjunto de datos.[5]

Distancias y similitudes

Las distancias y similitudes juegan un importante rol en el reconocimiento de patrones. En la literatura los términos: medidas de similitud, coeficiente de similitud y disimilitud o distancias son usadas para describir cuantitativamente de 2 puntos de datos o de 2 grupos.

En general, distancia y similitud son conceptos recíprocos. Frecuentemente, las medidas de similitud y los coeficientes de similitud son usados para

describir cuantitativamente qué tan similares son dos puntos o grupos de datos:[5]

Entre más grande es el coeficiente de similitud más similares son los patrones medidos.

Cada algoritmo de agrupamiento se basa en un índice de similitud o disimilitud entre patrones, si no hay medida de similitud o disimilitud entre pares de patrones, entonces no es posible tener un análisis de agrupamiento significativo.

Clases

Los términos clúster, grupo o clase han sido utilizados en una manera esencialmente intuitiva sin una definición uniforme. En general el uso común de las palabras anteriores combinará varios criterios plausibles y requerirá que todos los objetos en una clase:

- Compartan las mismas propiedades o que estén cercanamente relacionadas.
- Mostrar pequeñas distancias o disimilitudes mutuas.
- Tener contacto o relación con al menos algún otro objeto de la clase.
- Ser claramente distinguible de su complemento, por ejemplo el resto de los objetos del grupo de datos.

Grupos de datos

La materia prima con la que se trabaja en el reconocimiento de patrones son los grupos de datos, y es que a partir de estos, alimentaremos los algoritmos que desarrollemos, ya sea para entrenarlos o para evaluarlos, lo cual debe ser hecho con varios grupos de datos. En este sentido, los grupos de prueba tienen un rol muy importante en proceso de desarrollar el algoritmo. Al respecto de la presente tesis nuestra fuente de datos consistirá en imágenes con un tamaño definido de 630×450 pixeles de resolución en formato RGB.

Tipos de datos.

Los algoritmos de agrupamiento están muy asociados con los tipos de datos, de acuerdo con la figura 3.2, un tipo de datos se refiere al grado de cuantización en los datos, un atributo puede ser manejado como binario, discreto o continuo. Un atributo binario tiene exactamente dos valores, tales como verdadero o falso. Un atributo discreto tiene un número finito de valores posibles, por lo tanto, los tipos binarios son un caso especial de los tipos discretos.

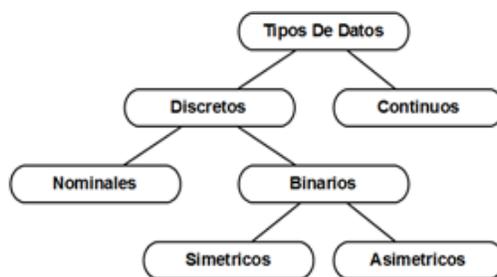


Figura 3.2: Tipos de datos en patrones.

Escalas de datos

Las escalas de datos, indican la relativa significancia de los números, que es un tema importante en reconocimiento de patrones. Las escalas de datos pueden ser divididas en: escalas cualitativas y escalas cuantitativas. Las escalas cualitativas incluyen escalas nominales y ordinales, mientras que las cuantitativas incluyen escalas de intervalos y escalas de proporción (razón).

Datos categóricos

Los atributos categóricos también referidos como atributos nominales, los cuales son simplemente usados como nombres tales como las marcas de los autos con los nombres de los bancos, dado que consideramos a los grupos de datos con un número finito de patrones, un atributo nominal de los patrones en el grupo de datos puede tener solamente un número finito de valores, por lo tanto, el tipo nominal es también un caso especial del tipo discreto.

Datos binarios

Un atributo binario es un atributo que tiene exactamente dos valores posibles tales como verdadero o falso, nótese que las variables binarias pueden a su vez ser divididas en dos tipos: las variables binarias simétricas y las variables binarias asimétricas, para las variables simétricas los dos valores son igualmente importantes, por ejemplo: "hombre", "mujer". Las variables binarias simétricas son variables nominales. En una variable asimétrica, uno de sus valores tiene más importancia que el otro, por ejemplo "sí" conlleva más importancia.

Datos simbólicos

Los datos categóricos y binarios son tipos de datos clásicos, y los datos simbólicos son una extensión de los tipos clásicos, en los grupos de datos convencionales, los objetos son tratados como individuos, mientras que en los grupos de datos simbólicos, los objetos están más unificados por medio de relaciones. Como tal, los datos simbólicos son más o menos homogéneos o el grupos de individuos. Para resumir, las diferencias entre los datos simbólicos y los datos convencionales se tiene que:

- Todos los objetos en un grupo de datos simbólico podrían no estar definidos sobre las mismas variables.
- Cada variable podría tomar más de un valor o intervalo de valores.
- Las variables en un grupo simbólico complejo de datos pueden tomar valores incluyendo uno o más objetos elementales.
- La descripción de un objeto simbólico puede depender en las relaciones existentes entre otros objetos.

Los valores que las variables toman pueden indicar la frecuencia de ocurrencia, semejanza relativa, nivel de importancia de los valores, entre otras cosas.

Series de tiempo

Las series de tiempo son la forma más simple de datos temporales. Precisamente una serie de tiempo es una secuencia de números reales que representan las mediciones de una variable real a intervalos regulares de tiempo,

por ejemplo, los movimientos de la bolsa, la temperatura de un lugar en específico.

Una variable de tiempo es discreta si la variable está definida sobre un conjunto finito de puntos de tiempo. Cuando una variable está definida en todos los puntos de tiempo, entonces la serie de tiempo es continua.

En general, una serie de tiempo puede ser considerada como una mezcla de los siguientes cuatro componentes:

- Una tendencia, por ejemplo, la tendencia a largo plazo.
- Fluctuaciones alrededor de la tendencia de mayor o menor regularidad.
- Un componente periódico.
- Un efecto residual o aleatorio.

Adicional a los tipos de datos mostrados anteriormente, en el mundo real existen otros tipos de datos como imágenes o datos espaciales.

3.3.2. Las tareas del reconocimiento de patrones.

Existen cuatro tareas importantes en el reconocimiento de patrones que son: clasificación, recuperación, regresión y agrupamiento (*clustering*), las 3 primeras bajo el paradigma de aprendizaje supervisado, y la última bajo el no supervisado.

Al respecto de la clasificación, esta se lleva a cabo mediante un sistema o una serie de pasos que por medio una función de distancia nos permitirán asignar a un dato una etiqueta con nombre de clase, dicho sistema también es conocido como clasificador.

Ejemplos de dichos algoritmos o sistemas son: las redes neuronales, los árboles de decisión, clasificador euclidiano, clasificador KNN, clasificador bayesiano, entre otros.

Dentro del área no supervisada de clasificación de datos, los métodos con base en agrupamiento de datos (*clustering*), parten de la premisa de que aun sin tener información de a qué clase pertenece cada elemento dentro de un

grupo de datos, se pueden formar cúmulos de los mismos partiendo de su topología intrínseca.

3.3.3. Clasificación

Para el diseño adecuado de un sistema de reconocimiento de patrones (clasificación) tenemos que considerar los siguientes aspectos (ver fig. 3.3):

- Tener acceso a una fuente de datos, con un número de patrones de origen conocido (si hablamos de sistemas supervisados).
- Identificar las cantidades medibles que hacen a los patrones distintos unos de otros (Selección de rasgos).
- Definir los límites de valores de rasgos dentro de los cuales los patrones pueden ser asociados a una y otra clase.
- Seleccionar un sistema de clasificación de patrones (Euclidiano, KNN, bayes, entre otros).
- Entrenar al mismo mediante una porción de la población total de datos.
- Finalmente, evaluar el desempeño del clasificador.

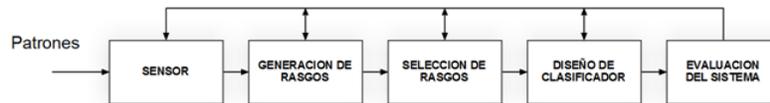


Figura 3.3: Pasos básicos de clasificación.

De forma tradicional, para el procesamiento de imágenes con objetivos de segmentación en el campo de visión artificial se recurre a la extracción de rasgos o de puntos de interés contenidos en la imagen, con base en las necesidades específicas de la aplicación o del usuario final.

Un paradigma para el reconocimiento de objetos se muestra a continuación [17] para un sistema de visión artificial (ver fig 3.3).

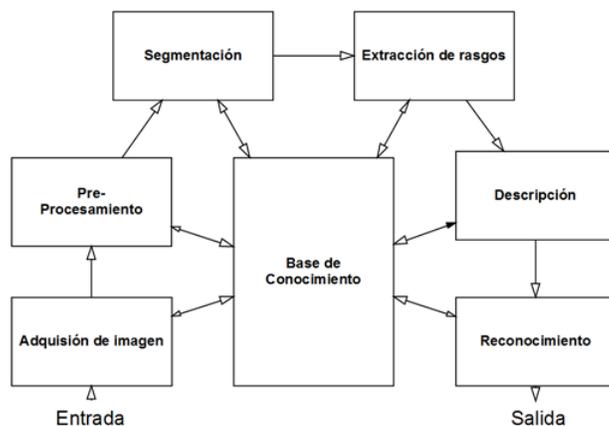


Figura 3.4: Paradigma de reconocimiento

En la extracción de rasgos se aplican algoritmos de extracción de líneas, de esquinas, de bordes o en general de puntos de interés, posterior a esto se procede a formar los patrones que serán alimentados a un algoritmo de clasificación para poder definir la clase a la que pertenecen.

Con el fin de validar la utilidad de los datos obtenidos por el sistema granular abordaremos dos de las tareas del reconocimiento de patrones, la primera será de clasificación mediante redes neuronales artificiales y la segunda, el clustering mediante 4 algoritmos: el fuzzy c-means, possibilistic c-means, Gustafson Kessel y conos danzantes, por lo cual procederemos a dar detalles de los mismos.

Perceptron

Concebido como un equivalente computacional de una neurona biológica, la red neuronal tipo Perceptron es el elemento de procesamiento básico en redes neuronales artificiales, está compuesto de 3 elementos: las dendritas de entrada, la función de suma de entradas ponderadas, que a su vez, es la entrada del tercer elemento, la función de activación, ver fig. 3.5

Siendo X un patrón de entrada n -dimensional, cada una de sus componentes (x_i) es ponderada por un vector de pesos W_j , correspondiente al j -ésimo elemento de procesamiento, obteniendo como resultado la ecuación 3.1

$$y_{in_j} = X \cdot W_j = \sum_{i=1}^n x_i \cdot w_{ij}. \quad (3.1)$$

si adicionalmente a lo anterior se incluye un elemento de "bias", obtenemos la ecuación 3.2, donde y_{in_j} será la entrada de la función de activación correspondiente a la neurona j

$$y_{in_j} = w_{oj} + \sum_{i=1}^n x_i \cdot w_{ij}. \quad (3.2)$$

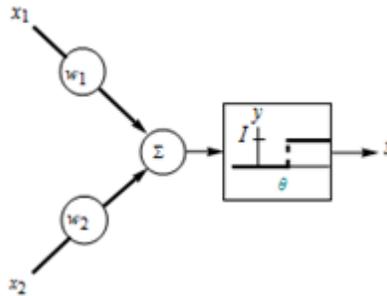


Figura 3.5: Modelo de la neurona perceptron

Redes neuronales multicapa de perceptrones

Si se simplifica el símbolo de la figura 3.5 a un nodo con múltiples entradas y una salida, y posteriormente se agrupan varios nodos en arreglos lineales se producen redes conectadas cuyas arquitecturas pueden ser como sigue:

Una de las arquitecturas de red neuronal más populares es la red de perceptrones multicapa (MLP), compuesta de una capa de entrada, una o más capas ocultas y una capa de salida. Cada capa contiene cierta cantidad de neuronas y todas las neuronas de las capas vecinas están interconectados ver figura 3.6.

Cada conexión en la red tiene un peso sináptico (w) asociado. La tarea de cada neurona es calcular la suma ponderada de sus entradas y transformarlo en una señal de salida. Esta transformación es hecha mediante una función de activación, existen varias funciones cuyo uso está determinado por la aplicación o rango de datos de entrada, aunque las más populares son: la

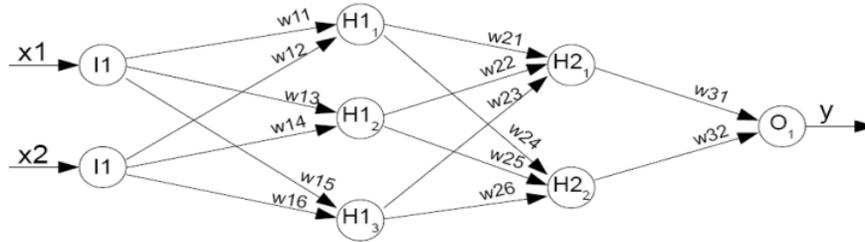


Figura 3.6: Arquitectura de una red neuronal de perceptrones multicapa, con dos neuronas de entrada, 2 capas ocultas con 3 y 2 neuronas, y una neurona de salida.

sigmoide y la gaussiana (siendo y_{in_j} el valor de entrada x , de las siguientes ecuaciones).

$$y = \frac{1}{1 + e^{(-x)}} , \quad y = e^{(-x^2)} \quad (3.3)$$

En una red de este tipo la señal se propaga hacia adelante (no tiene retornos) desde la capa de entrada, pasa a través de las capas ocultas y termina en la capa de salida donde se calcula la señal de salida.

Backpropagation

Una vez que se ha calculado la salida de la red neuronal, podemos comparar su valor con el valor de salida deseado, la diferencia entre estas dos señales es el error de la red, con el fin de reducir este error y obtener una buena coincidencia entre la salida de la red y los valores esperados, podemos iterativamente ajustar los valores de los pesos en la red hasta alcanzar un buen desempeño

Uno de los algoritmos más comúnmente utilizados para el ajuste de pesos es el de "back-propagation", el cual propaga el error de la capa de salida definido por la ecuación 3.4 hacia las capas antecesoras, siendo $d^{(k)}$ las salidas deseadas para el patrón k , y^k los valores obtenidos en la capa de salida de la red para el k -esimo patrón.

$$E(w) = \frac{1}{2} \sum_{k=1}^p (d^{(k)} - y^k)^2 \quad (3.4)$$

Posteriormente, se cambian los pesos de la red mediante la optimización de la función de error a través del algoritmo de gradiente descendiente como la siguiente[2], donde η es el factor de aprendizaje del algoritmo, y ∇ es la primera derivada del error con respecto a los pesos:

$$\Delta(w) = -\eta \nabla_w E(w) \quad (3.5)$$

Hay dos enfoques para el entrenamiento de retro propagación: el aprendizaje incremental (en línea) donde se actualizan los pesos justo después de haber presentado el patrón a la red, y el aprendizaje por lotes donde el valor de error es acumulado a lo largo de todos los patrones y sólo entonces se actualizan los pesos.[10]

De forma reducida el algoritmo consiste en los siguientes pasos:

- 1 Inicializar pesos, error deseado e_{max} y el núm. máximo de iteraciones itr_{max} , inicializar los deltas de peso y el número de iteración a cero;
- 2 **for** para todo patrón P en el conjunto de entrenamiento T **do**
- 3 Calcular el error en la neurona de salida $e_{out}^p = o^p - t^p$, donde o^p es la salida de la red y t^p es el valor esperado (objetivo) para el patrón p ;
- 4 retropropagación: Calcular los errores de las neuronas en las capas ocultas $e_{hid}^p = e_{out}^p * w_{hid} * dy(p)$, donde $d(y)$ es la derivada de la función de activación y ;
- 5 Calcular los deltas de peso $\Delta w_{ij}^p = \delta_j * o_i$, donde $\delta_j = dy_j(p) * e_{out}^p$ para las neuronas de la capa de salida, y $\delta_j = dy_j(p) * \sum_{k \in outp(j)} \delta_k * w_{ik}$ para las neuronas en las capas ocultas;
- 6 Acumular los deltas de peso calculados $\Delta w_{ij} = \Delta w_{ij} + \Delta w_{ij}^p$;
- 7 **end**
- 8 Actualizar los pesos mediante $w_{ij} = w_{ij} + \eta * \Delta w_{ij}$, donde η es el factor de aprendizaje;
- 9 Calcular el error cuadrático medio (MSE) del conjunto de entrenamiento T mediante $e_{out} = \frac{1}{|T|} * \sum_{p \in T} (e_{out}^p)^2$, donde $|T|$ es la cardinalidad de T (el número de patrones de entrenamiento);
- 10 **if** $e_{out} > e_{max}$ y $itr < itr_{max}$ **then**
- 11 incrementar el número de iteraciones y regresar al punto 2
- 12 **end**

Algoritmo 1: Algoritmo de entrenamiento "backpropagation"

3.3.4. Agrupamiento (Clustering)

Así mismo dentro del área no supervisada tenemos algoritmos para formación de clusters como son:

Fuzzy C-Means (FCM)

Es un algoritmo que maneja los datos de forma difusa es decir asociando un grado de pertenencia de la muestra a cada cluster. Es capaz de reconocer nubes esféricas de datos en un espacio p-dimensional. Los clusters se asume tienen un tamaño parecido y están representados por su centro también llamado prototipo, con respecto al cual se obtiene la distancia euclidiana de la muestra.

La función que se busca optimizar es:

$$J_1(U, v; X) = \sum_{k=1}^c \sum_{j=1}^M (u_{kj})^m (\|x_j - v_k\|)^2 \quad (3.6)$$

Sujeta a las siguientes restricciones:

$$\sum_{j=1}^c u_{ij} = 1 \quad (3.7)$$

$$\sum_{i=1}^n u_{ij} > 0 \quad (3.8)$$

Possibilistic C-means

Este algoritmo tiene el objetivo de mejorar el desempeño del algoritmo FCM al ser utilizados en conjuntos de datos con mucho ruido. Y se caracterizan por tomar a los valores de la matriz U (Donde cada elemento de U se define como u_{ij}) como grados de compatibilidad con los grupos en lugar de probabilidades de pertenencia mediante la eliminación de la restricción de las particiones difusas (eq.3.7) que obligan a que la suma de los grados de pertenencia de un elemento hacia todos los grupos sea uno y exigiendo que al menos uno de los grados de pertenencia sea positivo.

La función objetivo más comúnmente utilizada en este esquema es:

$$J_m(U, v, \eta) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m * d_{ik}^2 + \sum_{i=1}^c \eta_i \sum_{k=1}^n (1 - \mu_{ik})^m \quad (3.9)$$

Es decir la misma función que en los FCM pero con un término añadido que impide que la partición obtenida sea la solución trivial donde todos los valores de pertenencia son iguales a cero-

Gustafson Kessel

Si reemplazamos la distancia euclidiana por otra métrica inducida por una matriz simétrica definida positiva en el algoritmo fuzzy c-means, entonces clusters elípticos también pueden ser reconocidos en lugar de sólo los esféricos, además de que este algoritmo hace una adaptación automática a la forma de cada cluster individual. En comparación con el FCM, cada cluster se caracteriza por centro y una matriz simétrica definida positiva A , la cual permite adaptar la norma de distancia a la estructura topológica de los datos.

Hyperconic clustering (Conos Danzantes)

Para este esquema se usa un algoritmo tipo ACE (Alternating cluster estimation) y una función de membresía hiper-cónica definida como:

$$\mu_i(x) = \begin{cases} 1 - \frac{d_i(x)}{r_i} & \text{para } d_i(x) \leq r_i \\ 0 & \text{en cualquier otro caso} \end{cases} \quad (3.10)$$

Siendo $d_i(x)$ la distancia entre el punto x y el i -ésimo cluster. Para los clusters especificados con el centro v_i se usa la distancia euclidiana $d_i(x) = \|x - v_i\|$. Para la elección del radio del hipercono $r_i, 0 = 1, \dots, c$ usamos:

$$r_i = \frac{\sqrt{\sum_{l=1}^p S_l^2}}{c + 1} \quad (3.11)$$

Una de sus propiedades importantes es que sus funciones de membresía (los conos) cambian únicamente por la localización de sus centros (El estimado actual de V). Por lo tanto los conos están fijos en altura y radio de la base pero danzan alrededor mientras $V^{(t-1)} \rightarrow V^{(t)}$

A diferencia de otros algoritmos donde los centros pueden ser influenciados por puntos de datos muy distantes, en las funciones de membresía usadas

aquí, los centros de cada cluster son sólo afectados por los puntos de datos en la hiper-esfera local alrededor de v_i con radio r_i .

3.3.5. Matriz de confusión, Recuerdo y Precisión

Al evaluar el desempeño de un sistema de clasificación, la probabilidad de error, no es la única cantidad que mide el desempeño de manera suficiente. Por ejemplo, en un sistema de clasificación de M -clases, un problema importante es saber si existen clases con una alta tendencia a confundirse con otras. La matriz de confusión $A = [A(i, j)]$ está definida de modo que su elemento $A(i, j)$ es el número de puntos de datos cuya etiqueta verdadera de clase era i y fue clasificada como j , en otras palabras la matriz está estructurada de tal modo que en las filas están los valores reales y en las columnas los valores declarados por el clasificador. De A uno puede directamente extraer los valores de recuerdo ("recall") y precisión ("precision") de cada clase así como la exactitud (accuracy) global.[20]

Recuerdo (Recall, R_i).

R_i es el porcentaje de puntos de datos con verdadera etiqueta de clase i , que fueron correctamente clasificados del total en esa clase y en general para un problema multiclase se puede calcular como:

$$R_i = \frac{A(i, i)}{\sum_j A_{ij}} \quad (3.12)$$

Es decir, el valor de la diagonal correspondiente a la clase i entre la suma de los componentes de la fila para la clase i

Precisión (P_i)

P_i es el porcentaje de puntos del total de datos clasificados en la clase i y cuya clase verdadera es de hecho i , por lo tanto para un problema multiclase se calcula como:

$$P_i = \frac{A(i, i)}{\sum_j A_{ji}} \quad (3.13)$$

Es decir, el valor de la diagonal correspondiente a la clase i entre la suma de los componentes de la columna para la clase i

Exactitud global (Accuracy, Ac)

La exactitud global, Ac , es el porcentaje de datos que han sido correctamente clasificados. Dado un problema de M -clases, Ac es calculada de la matriz de confusión como:

$$P_i = \frac{1}{N} \sum_{i=1}^M A_{ii} \quad (3.14)$$

Donde N es el número total de puntos en el conjunto de prueba.

Desarrollo

4.1. La idea detrás de todo.

Ante la pregunta, cuando vemos, ¿cómo sabemos dónde termina un objeto y donde empieza otro? La respuesta rápida es que son los bordes o fronteras de cada objeto los nos permiten saberlo, y entonces la siguiente pregunta es ¿qué es la frontera de un objeto en el ámbito de nuestra percepción? La hipótesis es: el cambio de color.

La luz que entra por la pupila y es captada por la retina en 3 longitudes de onda principalmente, es codificada a nivel neuronal de tal manera que en nuestro consciente, a nivel de percepción, se genera un sistema de colores con el cual podemos representar fronteras de objetos usando los cambios de color que percibimos, cuan más abrupto es el cambio de color más nítida es la frontera, esto a su vez nos lleva a representar formas, lo cual en conjunto nos permite realizar los procesos de alto nivel que día a día nos permiten interactuar con el medio que nos rodea.

O resumido aún más, sabemos dónde empieza y termina un objeto por un cambio de color.

Bajo la idea anterior es que se inspira el proceso que se realizó en este trabajo, y que da lugar a los puntos a continuación descritos:

- Se requiere captar imágenes que codifiquen la información de color en una sola coordenada, para emular la forma en que percibimos nuestro entorno. La captura y representación más común de imágenes es el espacio de color RGB, donde el color en un pixel es una combinación de los 3 colores primarios, sin embargo esto no es útil para nuestro propósito, dado que cuando nosotros pensamos en color, no decimos, este objeto tiene 'X' porcentaje de rojo, 'Y' de verde y 'Z' de azul, en realidad sólo decimos es de color C, un solo valor, un solo concepto, por

este motivo es que el uso del espacio de color HSV es útil ya que con una sola coordenada (la correspondiente al matiz) nos permite asociar un concepto de color a un pixel.

- Como se mencionó, cuan más abrupto es el cambio de color, más nítida es la frontera, bajo este principio podemos definir que pixeles pertenecen a un objeto o a otro, simplemente comparando su color, si es muy alta la variación, los pixeles están en una zona de frontera y además pertenecerán a objetos distintos, una forma de modular la variación es mediante un factor de similitud ϕ , el cual, define cuanto puede variar el color de un objeto contiguo para determinar que es igual a sí mismo. Con un ϕ muy grande se permite considerar a dos pixeles con colores muy dispares como similares y si ϕ es muy pequeño, entonces solo se admitirán variaciones de color muy pequeñas para considerarlos similares.
- La similitud entre pixeles que estén inmersos en la misma escena nos permite formar entidades, que están conectadas solamente si sus miembros son similares, de la misma manera que nuestro cerebro asume que regiones del mismo color están conectadas y forman parte de una misma entidad; Entidades que describen a la imagen misma aunque de manera abstracta, para dar a nuestro cerebro entendimiento acerca de lo que estamos viendo.

4.2. Proceso general

El objetivo principal de este trabajo será clasificar una imagen de entrada en una de tres clases predefinidas como se muestra a continuación

Para lograr dicho objetivo una serie de pasos intermedios deben realizarse, consistentes en:

- Seleccionar la imagen que será procesada.
- Introducir la imagen al sistema granular, para obtener un patrón de dimensionalidad variable y significado posicional también variable (PDSV), término que será detallado en la subsección 4.5.1.
- Convertir el PDSV a un vector o patrón de dimensionalidad y significado posicional fija (patrón común)



Figura 4.1: Objetivo a lograr, clasificar imágenes

- Introducir el patrón a un sistema de clasificación.

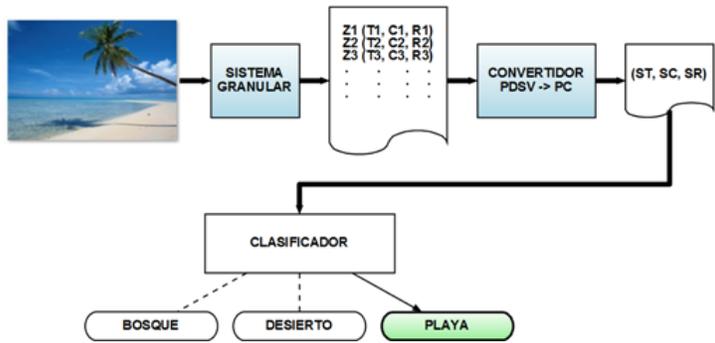


Figura 4.2: Detalle del Objetivo a lograr

4.3. Los datos de entrada: Las imágenes

Para poder tener una cantidad uniforme de datos en el sistema que nos permita representar sin ambivalencias a una misma imagen, las imágenes de entrada fueron normalizadas a un tamaño de 630 X 450 pixeles en formato de almacenamiento RGB de 8 bits

Cada imagen RGB está compuesta de 3 matrices de datos de 630 X 450 datos enteros, siendo la primera para el canal rojo, la segunda para el canal verde y la última para el canal azul.

Para efectos de tener la componente que representa al color, la imagen en RGB debe ser convertida al espacio de color HSV, del resultado únicamente consideraremos la matriz de matiz (*HUE*) como se muestra a continuación.

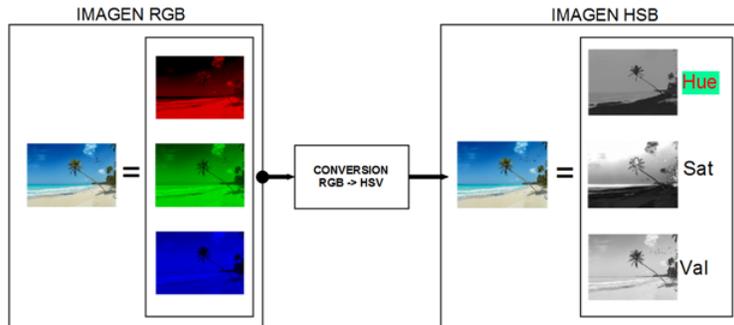


Figura 4.3: Componentes de una imagen en espacio de color RGB y HSV

Al respecto de, ¿Por qué se necesita cambiar al formato HSV? como se mencionó anteriormente, mediante la elección del formato HSV (*Hue Saturation and Value*, por sus siglas en inglés) para la representación de imágenes, la información de color se condensa en una sola coordenada, por otra parte ¿Porque el matiz? esto es debido a que esa componente es la correspondiente al color.

4.4. El sistema granular

El sistema granular es el encargado de recibir una imagen como entrada y devolver a la salida un patrón de dimensionalidad y significado variable. Para lograr dicho cometido está compuesto de una serie de pasos que son:

- Aplicar la matriz de valores de matiz (*HUE*) a la capa de entrada de la jerarquía granular.
- Realizar operaciones de promediado en la primera capa y transferir información a la segunda.
- Los gránulos de la segunda capa definirán conectividad con sus vecinos inmediatos
- Los gránulos de la segunda capa obtendrán valor promedio por zona por medio de un algoritmo distribuido.
- La capa 2 colectara las zonas conectadas y generará el PDSV.

Una vista estructural del sistema granular es como sigue:

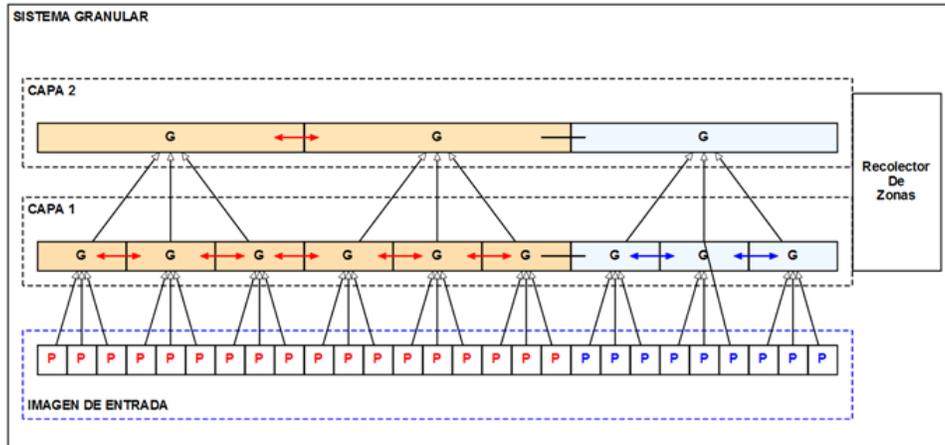


Figura 4.4: Estructura del sistema granular

De forma lateral, podemos ver en la parte inferior la imagen de entrada, conformada de píxeles de matiz (P) que entran al sistema, y las capas del mismo que están formadas de gránulos (G), cada uno de los cuales funciona como una unidad de procesamiento independiente que calcula la conexión con sus vecinos inmediatos cuando recibe su respectiva señal de disparo. Lo anterior da como resultado la formación de zonas de gránulos conectados debido por la similitud del color que poseen. Lo cual puede entenderse como una segmentación de la imagen de entrada inicial, a la par está el sistema para recolectar las zonas obtenidas de cada capa.

4.4.1. Gránulos

Los gránulos son el elemento básico de construcción del sistema, contienen métodos que calculan la conexión con sus vecinos inmediatos. Y tienen propiedades que les permiten ejecutarse de manera concurrente para interactuar con otros gránulos.

Detallando el concepto y la implementación de los gránulos (G), tenemos que cada uno es capaz de recibir 9 datos, ya sean píxeles de una imagen o salidas de otros gránulos. Cada gránulo puede calcular la intensidad o energía promedio (E_{prom}) de los datos que tiene asociados. Puede definir conectividad con alguno de sus vecinos dependiendo del valor de intensidad de ambos.

Los gránulos son cuatro conectados es decir que el análisis para la obtención de vecindades conectadas entre ellos simplemente se hará con el gránulo que este al norte, sur, este u oeste, las porciones diagonales están descartadas.

Los gránulos propuestos definen su conectividad de forma binaria, entera, como 1 para conectado y 0 para no conectado ya que esto simplifica los cálculos de zonas conectadas.

Cada gránulo compara la diferencia que existe entre el valor que tiene el gránulo en cuestión y su vecino inmediato.

En general la entrada inicial de información son pixeles, pero las operaciones se hacen entre gránulos, y es en estos donde para definir conectividad utilizaremos el factor de similitud (ϕ) cuya función es indicar cuanto puede variar el valor de intensidad del gránulo vecino con respecto al actual para decir que están conectados.

Sea el nivel N el número de elementos de entrada (I) con energía (M) que puede almacenar un gránulo, entonces. Podemos definir el promedio de matriz o energía del gránulo como sigue:

$$E_{prom} = \frac{\sum_{n=1}^N M_{In}}{N} \quad (4.1)$$

A su vez, tenemos el factor de similitud (ϕ) que es aplicado al promedio de energía de la siguiente forma:

$$E_{perc} = E_{prom} * \phi \quad (4.2)$$

El valor valor E_{perc} es sumamente importante dado que establece la variación máxima que puede tener el promedio de energía de un gránulo vecino para definir si está conectado o no con el actual.

Para lo anterior debemos calcular la diferencia de energías promedio entre el gránulo actual (E_{prom})y el vecino (E_{promN}) lo cual está dado por:

$$\Delta E_N = |E_{prom} - E_{promN}| \quad (4.3)$$

Y finalmente podemos llegar a establecer la conectividad del gránulo actual con el vecino inmediato de indice ω mediante la siguiente formula:

$$C(\omega) = \begin{cases} 1 & \text{si } \Delta E_n \leq E_{perc} \\ 0 & \text{si } \Delta E_n > E_{perc} \end{cases} \quad (4.4)$$

Dado que trabajamos con gránulos 4-conectados, el valor de ω va de 1 a 4, por otro lado el valor de $C(\omega)$ será: 1 para indicar conexión y 0 para desconexión,

Con $C(\omega)$ de forma binaria y en cuatro direcciones, entonces cada gránulo tiene cuatro variables binarias que almacenan su estado de conexión, si agrupamos estas cuatro variables en una sola, tendremos una manera simple de ahorrar espacio, resumir y operar las conexiones mediante un número binario de 4 bits, en donde el primer bit de derecha a izquierda corresponde a la conexión con el vecino inferior, el segundo con el superior, el tercero con el derecho y el cuarto con el izquierdo, a este número, lo llamaremos índice de conectividad (CI), que indicará que tan conectado se encuentra un gránulo, siendo el valor de 0 para ninguna conexión y 15 para totalmente conectado.

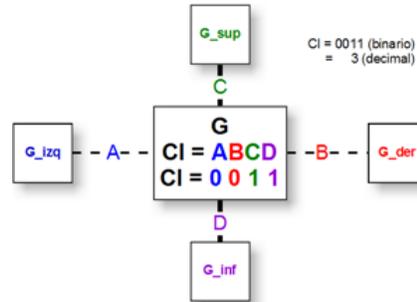


Figura 4.5: gránulo y su relación con el índice de conectividad

Algoritmo distribuido

Para formar zonas de gránulos conectados con valores uniformes, se dotó de un algoritmo distribuido a cada gránulo que le ayuda a homogenizar el valor que caracteriza a dicha zona.

El algoritmo distribuido permite a los gránulos comunicarse y llegar a un resultado, que es, segmentar la versión abstraída de la imagen, y es el

siguiente:

```
1 image mapping and initialization of granules;
2 while not terminated do
3   read current;
4   if New msg received then
5     if msg = "START" then
6       if Started = false then
7         Started = true;
8         Send Msg("START") to connected neighbors;
9       end
10    else if msg == "HOMOGEN" then
11      if Started = false then
12        Started = true;
13        Send Msg("HOMOGEN", Energy) to connected
14        neighbors;
15        Send Msg("NCSTART", 0) to UN-connected neighbors;
16      end
17    else
18      if ReceivedEnergy > Energy then
19        Energy = ReceivedEnergy;
20        Send Msg("HOMOGEN", Energy) to connected
21        neighbors;
22      end
23    end
24    else if msg == "NCSTART" then
25      if Started = false then
26        Started = true;
27        Send Msg("HOMOGEN", Energy) to connected
28        neighbors;
29        Send Msg("NCSTART", Energy) to UN-connected
30        neighbors;
31      end
32    else
33      display condición invalida;
34    end
35  end
36 end
```

Algoritmo 2: Algoritmo distribuido para homogenización

Con el algoritmo mostrado logramos que los gránulos conectados compartan un valor común, con el cual puedan identificarse y por consiguiente ser etiquetados, como es requerido en un proceso de segmentación.

Una de las ventajas de obtener la información de bordes a nivel local mediante un método que utiliza elementos puramente locales es que puede definir datos de conectividad aún cuando las variaciones de intensidad entre dos regiones distantes de una imagen sean elevadas.

4.4.2. Capas de gránulos (Layers)

Las capas son la estructura en la que están inmersos los gránulos, son el bloque básico de construcción para generar una jerarquía granular a la que introduciremos datos y nos arrojará resultados.

Para el caso concreto de este estudio su estructura es de forma matricial, y entre sus funciones están: transferir los valores de similitud definidos por el usuario a cada uno de los gránulos que aloja, mapear los valores de energía de gránulos en capas inferiores a los gránulos correspondientes y recolectar los resultados de cada gránulo, para su posterior procesamiento.

Asimismo provee un mecanismo para notificar del progreso del sistema granular al usuario.

Finalmente pero no menos importante realiza la segmentación de la imagen abstraída en ese nivel de resolución al procesar las secuencias de zonas que la describen.

Para lo cual se divide la imagen de entrada en nueve zonas y se etiquetan como se muestra a continuación:

1	2	3
4	5	6
7	8	9

Figura 4.6: Zonas en las que se divide la imagen

El número de cada región será usado para denotar la región en la que el centroide de la zona conectada fue localizado. Esto con el objetivo de proveer a las zonas de un atributo unidimensional para localizarlas y hacer más sencilla su visualización (Pues sólo se requieren 3 dimensiones en lugar de 4).

4.4.3. Jerarquía

La estructura en la que se alojan las capas granulares es una jerarquía, donde la imagen a procesar esta mapeada a la base de la misma y conforme más aumenta el nivel de la capa, más aumenta el grado de abstracción de la imagen procesada.

Etapa de filtrado

La primera capa del sistema granular más que ser un asociador de gránulos es usada como un suavizador de los elementos de entrada para reducir el impacto del ruido en la posterior granulación de los datos y lo que hace es calcular la energía promedio de los gránulos en la capa 1, mediante lo indicado en la sección 4.4.1, una vez que todos los gránulos han calculado sus valores promedio, toda la información se transfiere a la siguiente capa,

Etapa de conexiónado

En la capa 2, que es de orden superior se reciben los datos suavizados de la capa 1, aquí cada gránulo comparará la información de si mismo y cada uno de sus vecinos para determinar su índice de conectividad.

Una vez que todos los gránulos se encuentran sincronizados un algoritmo distribuido es lanzado para que los gránulos establezcan el valor común con el que denotarán a una zona conectada.

Una vez procesadas todas las capas obtendremos una serie de matrices de conectividad que nos indican las zonas que están conectadas. Es decir vamos a tener una imagen segmentada, cabe aclarar que la imagen que se obtiene no es la original sino una versión abstraída y de menor tamaño que la original, lo cual genera una ventaja al sistema de obtención de rasgos y clasificación,

y es que la cantidad de datos a procesar es mucho menor, lo cual redundará en un menor tiempo requerido para obtener un resultado.

Etapa de recolección de zonas

Aquí se genera el listado de zonas conectadas que componen la imagen, esto por medio de un barrido en la capa de gránulos o vista granulada para hacer un conteo de elementos conectados usando el índice de conectividad (CI) obtenido con la ecuación 4.4.,.

Durante el barrido, los gránulos que tienen un índice de conectividad mayor a cero son añadidos a una lista de zonas en la que también se almacena el valor común que comparten y finalmente se calcula en la ubicación del centroide de dichos gránulos conectados para establecer el sector de la imagen en el que dicho centroide está localizado.

4.4.4. Salida del sistema granular.

Una vez que el sistema granular haya procesado una imagen, esta quedará reducida a una secuencia de tripletas de números, donde cada tripleta tendrá como primer rasgo el tamaño de la zona, el segundo será el color asociado a esa zona y finalmente el tercero será el número de la región en la que fue encontrado el centroide de dicha zona.

Es de destacar que la cantidad final de zonas está muy de la mano del factor de similitud que se encuentra almacenado en cada gránulo, para valores de ϕ muy altos tendremos pocas zonas con tamaños grandes, mientras que para valores bajos tendremos una mayor cantidad de zonas pero de menor tamaño.

4.5. Convertidor PDSV a PC

4.5.1. Estructura de un PDSV

El resultado principal del sistema granular es que abstraigamos una imagen (I) a un conjunto de zonas (Z), entonces una imagen con contenido complejo

puede ser representada como un vector I con una dimensionalidad n igual al número de zonas obtenida.

$$I = \{Z_1, Z_2, \dots, Z_n\}$$

Cada zona está compuesta de 3 atributos que son: Tamaño de la zona (T), color de la zona (C) y región en la que se encuentra su centroide (K), entonces podemos re-escribir el patrón como:

$$I = \{(T_1, C_1, K_1)_1, (T_2, C_2, K_2)_2, \dots, (T_n, C_n, K_n)_n\}$$

A este tipo de estructura la llamaremos **Patrón de Dimensionalidad y Significado Variable (PDSV)**.

Notemos que al comparar una zona con otra dentro de un PDSV estas representan algo distinto, pero tienen la misma dimensionalidad y estructura.

En comparativa, en un sistema tradicional de clasificación el científico de datos tendrá que primero hacer una caracterización de los objetos con los que trabajará, para poder elegir las características más representativas con las que abstraerá el objeto y que le permitirán discernir entre una clase u otra de objetos.

Posteriormente creará un sistema de información fijo, en el que sabremos de antemano que el primer atributo siempre estará asociado a la característica "A", y el segundo a la característica "B" y así sucesivamente.

Un ejemplo clásico, para clasificar naranjas y manzanas, podríamos definir patrones que consten del diámetro de la fruta en el primer rasgo y del color en el segundo.

Hecho esto, podremos abstraer cada objeto de estudio a un vector (patrón) de dimensión fija, en el cual sabremos que siempre la primera coordenada será el diámetro del objeto y la segunda coordenada será un valor asociado al color, dichos patrones pueden ser introducidos a un clasificador convencional el cual por medio de una función de distancia asociará una clase a cada patrón

4.5.2. Dimensionalidad Variable

Por otra parte, la cantidad de zonas que arroja el sistema granular para una imagen puede variar de una imagen a otra, o dependiendo del factor ϕ que se utilice, la cantidad de zonas puede variar para una misma imagen. Esto

tiene como consecuencia que una misma muestra (imagen) puede ser representada por una o varias zonas que de manera constructiva conceptualizaran a la muestra.

4.5.3. Significado Posicional Variable

Supongamos que dos imágenes pertenecientes a una misma clase como las mostradas en la figura 4.7 al ser introducidas al sistema granular arrojan un par de listados de zonas, considerando que en dichos listados las zonas están ordenadas por el tamaño que tienen, entonces vemos que para la imagen I_1 , las zonas dos y tres no representan lo mismo que para las esas mismas posiciones en la imagen I_2 .



Figura 4.7: Ejemplo de significancia variable.

De lo anterior vemos que a diferencia de un patrón convencional, una zona en una posición dada no necesariamente tiene el mismo significado de una imagen a otra; Por lo que en un patrón del tipo PDSV el primer atributo asociado a una característica en la muestra A, no necesariamente representa a esa misma característica en la muestra B.

4.5.4. Aplicabilidad en clasificadores convencionales.

El uso de este tipo de vectores tiene el inconveniente de no ser aplicable a un clasificador convencional, porque estos últimos sólo admiten un número de entradas fijo al momento de ser entrenados y utilizados, incluso si se considerase aplicar los PDSVs a un sistema con un gran número de entradas y tratar las muestras con menos atributos como faltantes o valores vacíos, no es posible aplicar algún método de relleno de faltantes debido al significado

posicional variable.

Este hecho no permitiría que un sistema de reconocimiento de patrones utilice dichos atributos mediante una función de distancia para clasificar.

Resumiendo, tenemos patrones de dimensión variable de un objeto a otro y el significado de un rasgo en la misma posición de un patrón a otro es variable. Lo cual no permite aplicar los datos así obtenidos a un sistema de clasificación convencional, donde en general los rasgos son de dimensionalidad y significado posicional fijo.

4.5.5. Ventajas de los PDSV

La ventaja principal del uso de estos vectores, es que, sin necesidad de introducir algoritmos de normalización de atributos, es posible operar un atributo constructivo con otro bajo operaciones simples como la suma vectorial, mientras que en un patrón convencional la suma de atributos descriptivos rara vez tiene significados útiles.

4.5.6. Construcción y representación conceptual

Asumiendo que se tiene un espacio en el que las características de un objeto pueden ser representadas como vectores, y que además dichas características son operables de manera tal que al conjuntarse logran una representación del objeto, entonces, la calidad de dicha representación será directamente proporcional al número de características disponibles con las que fue construido.

Dado lo anterior podemos decir que tenemos un sistema con la capacidad de representar el concepto de un objeto (o imagen) de manera que los elementos constituyentes puedan ser sumados para construir un concepto.

Asumiendo que el contenido de una imagen I_A puede ser abstraído en la cantidad de elementos conectados que contiene. Los patrones del tipo PDSV tienen posibilidades para ser aplicados en la descripción conceptual de una imagen y dado que representan elementos genéricos contenidos en la misma pueden ser usados para generar representaciones conceptuales únicas en un

espacio construido a partir de los atributos que conforman al PDSV por lo que obtendríamos un patrón PDSV I_{AA} como versión abstraída de I_A .

Dado que los elementos constituyentes de I_{AA} son zonas Z_x que pueden ser operables unas con otras, entonces podemos construir el concepto I_{AAA} de la imagen I_A mediante la suma atributo a atributo de cada una de las zonas que constituyen a I_{AA}

Es decir, siendo D la dimensionalidad de I_{AA} (La cantidad de zonas que contiene) y R la dimensionalidad de Z entonces:

$$I_{AAA} = \left\{ \left(\sum_{n=1}^D T_{Z_n} \right)_1, \left(\sum_{n=1}^D C_{Z_n} \right)_2, \dots, \left(\sum_{n=1}^D K_{Z_n} \right)_R \right\}$$

Una vez que el concepto de imagen ha sido construido a partir de sus componentes constituyentes, esta puede ser representada por un punto único (I_{AAA}) en dicho espacio conceptual. Este punto único es en sí mismo ya un patrón convencional. La unicidad de la representación está sostenida por el hecho de que, la cantidad de elementos que pueden constituir a la representación del concepto está limitada porque la entrada de información también lo está, es decir, la cantidad de pixeles con los que se forman las imágenes están limitados también, por otro lado pueden presentarse construcciones que mapeen al mismo punto pero dada la forma de construir el sistema estas construcciones tendrán que ser similares a la entrada original.

A continuación, se muestra un ejemplo para la construcción del concepto de una imagen, basado en una estructura de zona en R2, dicha estructura sólo considerara como atributos el color y tamaño de las zonas conectadas, entonces de la figura, podemos ver que tendremos una zona de color rojo con tamaño de 13 gránulos y un valor de color (matiz) de 10 (correspondiente al rojo en HSB) y lo mismo aplicará para las dos zonas restantes.

Con la suma coordenada a coordenada de las zonas obtenemos un vector (I_{AAA}) que conceptualiza la imagen analizada en un punto del espacio de suma de tamaños y suma de color.

Resumiendo tenemos un sistema constructivo en un espacio conceptual que es resultado de la composición de todas las zonas que integran al patrón en cuestión.

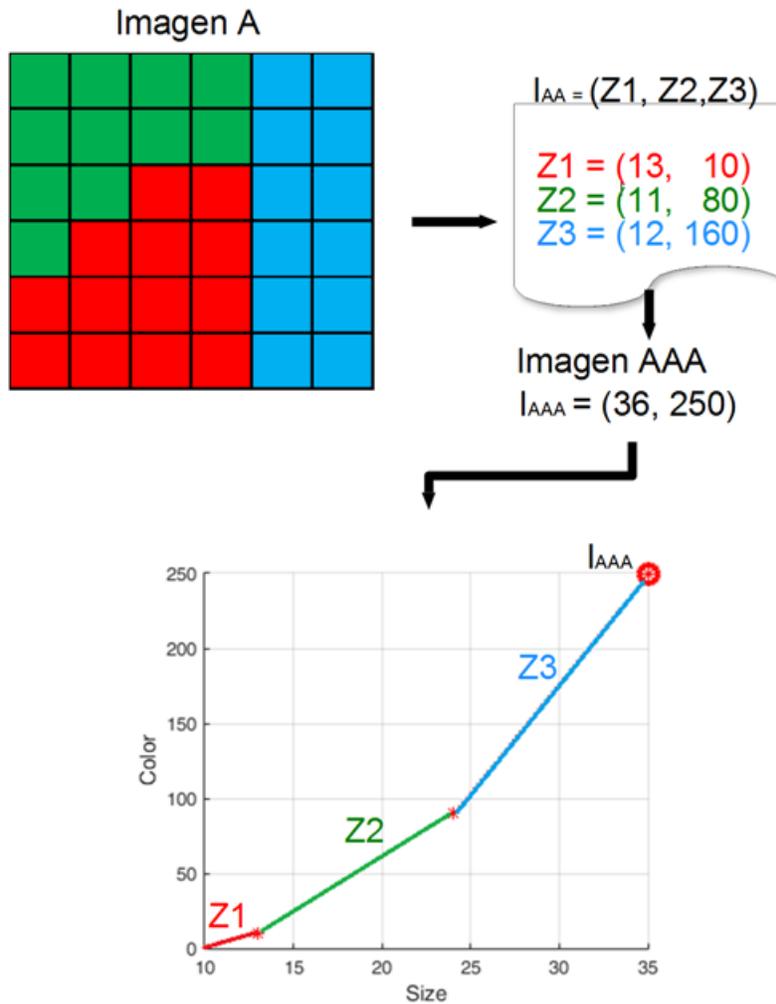


Figura 4.8: Construcción de concepto en R2

La cantidad de atributos o dimensionalidad de la zona depende de la riqueza de información que se quiera dar a las mismas.

Conversión de dimensionalidad variable a fija

Dado lo anterior, el objetivo del convertidor PDSV a PC de este estudio es: realizar la conversión de un patrón resultante del sistema granular a un patrón convencional en R3; Para este estudio la tercera coordenada será la región en la que el centroide de zona fue localizado, con lo cual se compondrán

tripletas que posteriormente se sumarán coordenada.

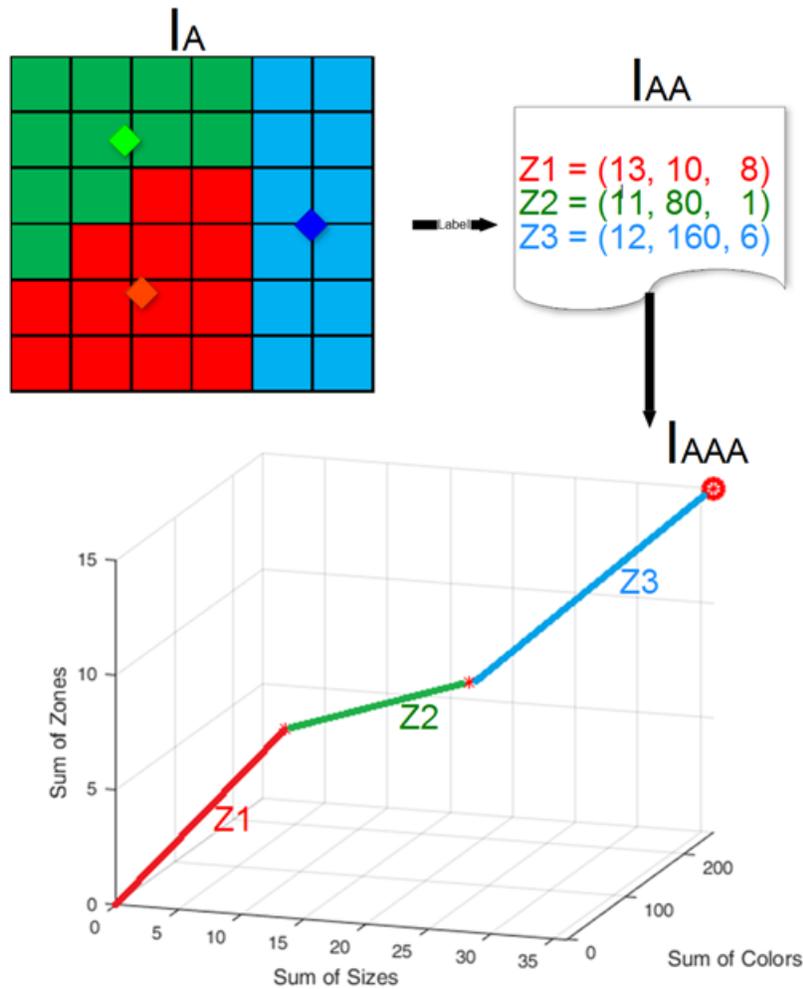


Figura 4.9: Construcción de concepto en R3

Lo anterior, tiene la ventaja de fijar el número de rasgos del patrón final que describirá al objeto y otorgarle un significado fijo a cada uno de los rasgos del mismo.

Por lo tanto, ahora es posible introducir los datos a un clasificador convencional como lo es una red neuronal, o a un sistema de agrupamiento no supervisado.

4.6. Clasificación

Cuando los patrones convencionales de imágenes similares son graficados en el espacio conceptual correspondiente, estos forman cúmulos de datos que son susceptibles de ser clasificados mediante un sistema convencional. Se muestran a continuación las nubes de datos que serán clasificadas o agrupados según sea el caso, los puntos en color rojo denotan los patrones correspondientes a la clase "playa", los verdes a la clase "desierto" y los azules a la clase "bosque".

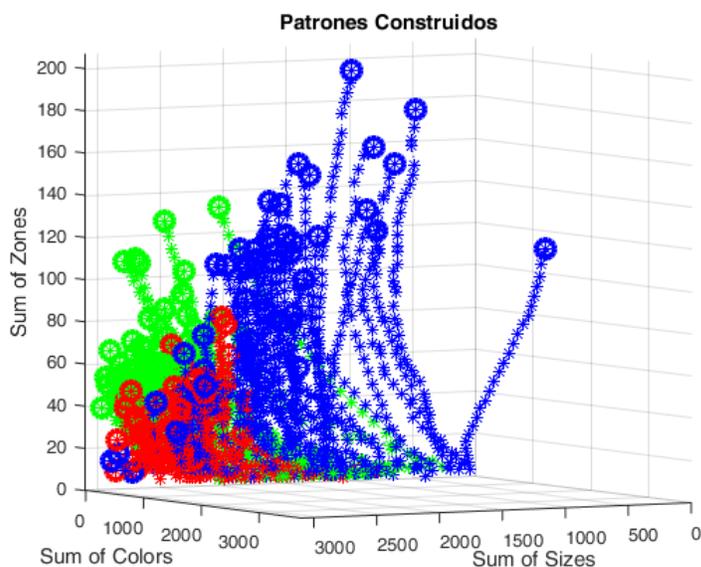


Figura 4.10: Nubes de datos

A continuación en el siguiente capítulo, se muestran los resultados obtenidos al aplicar esta metodología.

Experimentos y Resultados

5.1. Del sistema granular

En esta sección comenzaremos mostrando dos experimentos, el primero a nivel demostrativo para entender el tipo de imágenes que se generan en cada capa del sistema granular y el segundo para mostrar el efecto que tiene el factor de similitud en la abstracción de imagen resultante.

5.1.1. Experimento 1

El sistema granular obtuvo versiones abstraídas de todas las imágenes que se introdujeron, con resultados similares a las 3 muestras presentadas en la siguiente imagen, donde la primer columna corresponde a la imagen de entrada, la segunda a la versión en HSV abstraída en la primera capa y la tercera a la versión conectada de la segunda capa:

De la tercer columna se obtuvieron zonas conectadas (ZC) que son representativas de la imagen como versión abstraída y que además da lugar a la siguiente tabla donde se muestra que la cantidad de zonas varia de una imagen a otra, lo cual es dependiente de factores como: La cantidad de objetos en la imagen, que tan contrastantes son entre ellos y si la imagen contiene mucha información de textura.

Es por esto que si consideramos la imagen de playa vemos que se tienen 4 zonas, para las muestras de desierto y bosque tenemos 11 y 9 zonas respectivamente, esto debido a que las estas dos imágenes presentan más información de textura y ver fig 5.1.

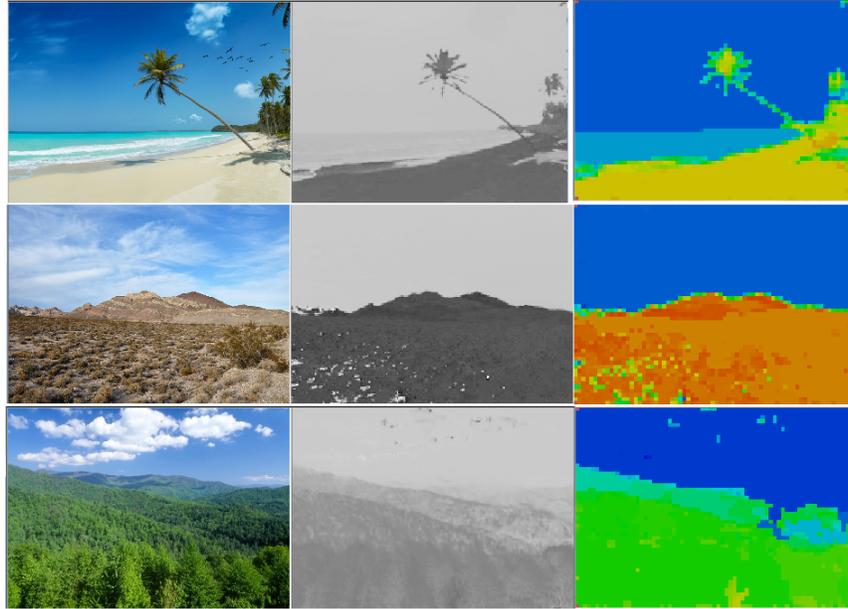


Figura 5.1: Versiones abstraídas para varias clases, columna1-original, columna2-salida de capa 1, columna 3- salida capa 2 abstraída

# de Zona	Tamaño	Color	Centroide	Clase	Tamaño	Color	Centroide	Clase	Tamaño	Color	Centroide	Clase
1	1927	152	4	1	1576	151	4	2	1411	158	4	3
2	506	40	6		591	27	9		759	73		6
3	328	138	6		74	21	3		204	80		2
4	22	49	8		69	23	6		161	75		9
5					61	26	6		56	109		5
6					48	24	6		54	118		2
7					46	20	3		37	96		5
8					45	22	3		30	79		2
9					44	19	6		28	108		2
10					41	18	6					
11					32	17	6					

Figura 5.2: Zonas obtenidas para las muestras anteriores

5.1.2. Experimento 2

La cantidad y tamaño de las ZC que componen a la PDSV está en función del factor de similitud ϕ

Para verificar lo anterior se tomaron 10 muestras de la clase playa, las cuales fueron introducidas al sistema granular, del PDSV resultante se tomó la cantidad total de zonas que lo componen (dimensionalidad) y del tamaño de zona máximo encontrado para un ϕ . Lo anterior dio como resultado la siguiente tabla:

PHI (%)	MUESTRA										Prom	Max	Min
	1	2	3	4	5	6	7	8	9	10			
1	9	14	12	7	7	6	9	29	5	7	10.5	29	5
2	8	19	11	8	8	5	8	7	5	6	8.5	19	5
3	3	14	10	5	6	5	6	7	4	6	6.6	14	3
4	3	10	10	7	8	2	4	7	4	4	5.9	10	2
5	3	16	10	6	5	2	4	2	3	6	5.7	16	2
6	3	15	8	8	4	2	4	3	3	7	5.7	15	2
8	3	12	12	5	7	2	5	5	4	5	6	12	2
10	3	12	10	6	6	2	9	3	3	5	5.9	12	2
20	3	6	4	2	4	1	2	4	5	4	3.5	6	1
30	1	5	2	1	2	1	2	2	4	2	2.2	5	1
40	1	2	1	1	1	1	1	3	1	2	1.4	3	1
50	1	3	1	1	1	1	1	1	1	1	1.2	3	1

Tabla 5.1: ϕ y cantidad de zonas resultantes

La tabla 5.1 muestra el impacto de ϕ en la cantidad de zonas resultantes mientras que la tabla 5.2 muestra el impacto en el tamaño de zona máximo encontrado.

Como resultado se observa que, a un ϕ más grande tenemos ZC's más grandes pero en menor cantidad, mientras que para un ϕ en el rango del 1 al 50% se genera una mayor cantidad de ZC's pero de menor tamaño, de manera complementaria se muestra la siguiente grafica que resume los datos de las tablas.

PHI (%)	MUESTRAS										Prom	Max	Min
	1	2	3	4	5	6	7	8	9	10			
1	1282	1820	1196	1959	1649	1543	1427	226	2247	837	1418.6	2247	226
2	1330	1869	1234	2103	1766	1862	1673	1097	2012	1606	1655.2	2103	1097
3	1360	1875	1237	2214	2211	1862	1761	1814	2480	2231	1904.5	2480	1237
4	1360	1898	1235	2241	2224	1896	1787	1923	2518	2265	1934.7	2518	1235
5	1630	2255	1726	2289	2388	1901	1801	1999	2554	2276	2081.9	2554	1630
6	1634	2265	1738	2299	2324	1903	1821	2058	2571	1563	2017.6	2571	1563
8	1636	2284	1739	2340	2348	1919	1841	2123	2623	2350	2120.3	2623	1636
10	1632	2310	1748	2356	2364	1947	1843	2189	2646	2371	2140.6	2646	1632
20	1606	2412	1805	3154	2442	3176	2954	2429	2786	2439	2520.3	3176	1606
30	1688	3242	1936	3257	2629	3228	3180	2485	2875	2668	2718.8	3257	1688
40	3257	3111	3151	3260	3225	3253	3229	2543	3237	2807	3107.3	3260	2543
50	2539	3262	3173	3249	3256	3262	3263	3239	3263	3252	3175.8	3263	2539

Tabla 5.2: ϕ y tamaño de zona máximo encontrado

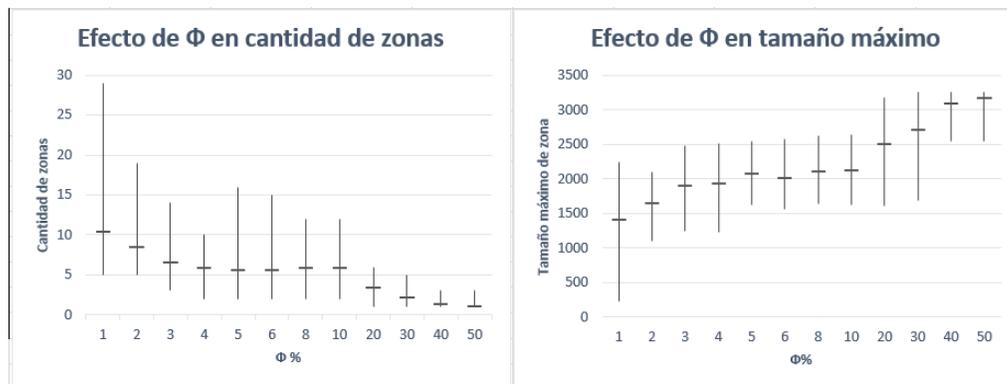


Figura 5.3: Influencia de ϕ en cantidad y tamaño máximo de zonas conectadas

En conclusión, de lo anterior se aprecia que el factor ϕ modula el grado de compacidad de un grupo (*cluster*); Cuando varios grupos están en un mismo espacio de representación, la compacidad de cada cluster, producirá o no traslape entre clases lo cual en consecuencia simplifica o dificulta la tarea de clasificación o clustering, por lo tanto la elección adecuada del factor ϕ aporta valor al sistema granular.

5.2. Del sistema de representación conceptual

En esta sección visualizaremos los cúmulos de datos que se generan para cada clase de imágenes.

5.2.1. Experimento 1

Al respecto de la representación de imágenes en un espacio conceptual, se introdujeron las siguientes muestras, para generar sus nubes correspondientes, es importante resaltar nuevamente que todas las imágenes fueron normalizadas a un tamaño de 630X450 pixeles para hacer posible la representación del objeto de manera que se eviten representaciones incorrectas.

Para cada clase se muestran las siguientes imágenes correspondientes a las siguientes clases:

- 50 imágenes para la clase "playa"
- 50 imágenes para la clase "desierto"
- 50 imágenes para la clase "bosque"
- 50 imágenes para la clase "escena de prueba 1 ESCOM"
- 50 imágenes para la clase "escena de prueba 2 CIC interior"

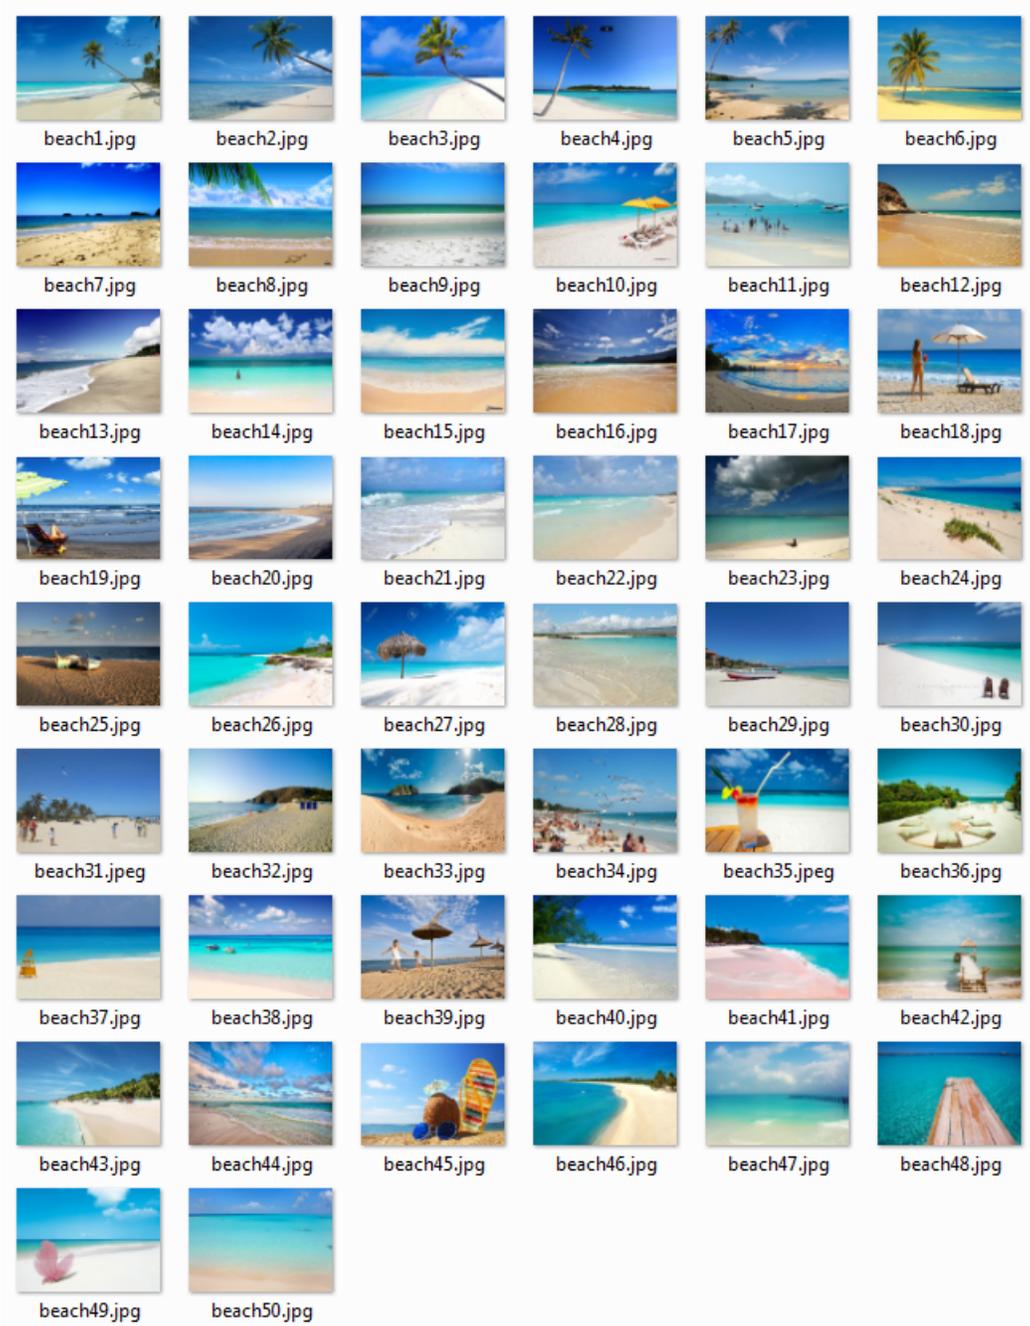


Figura 5.4: Imágenes usadas para la clase playa

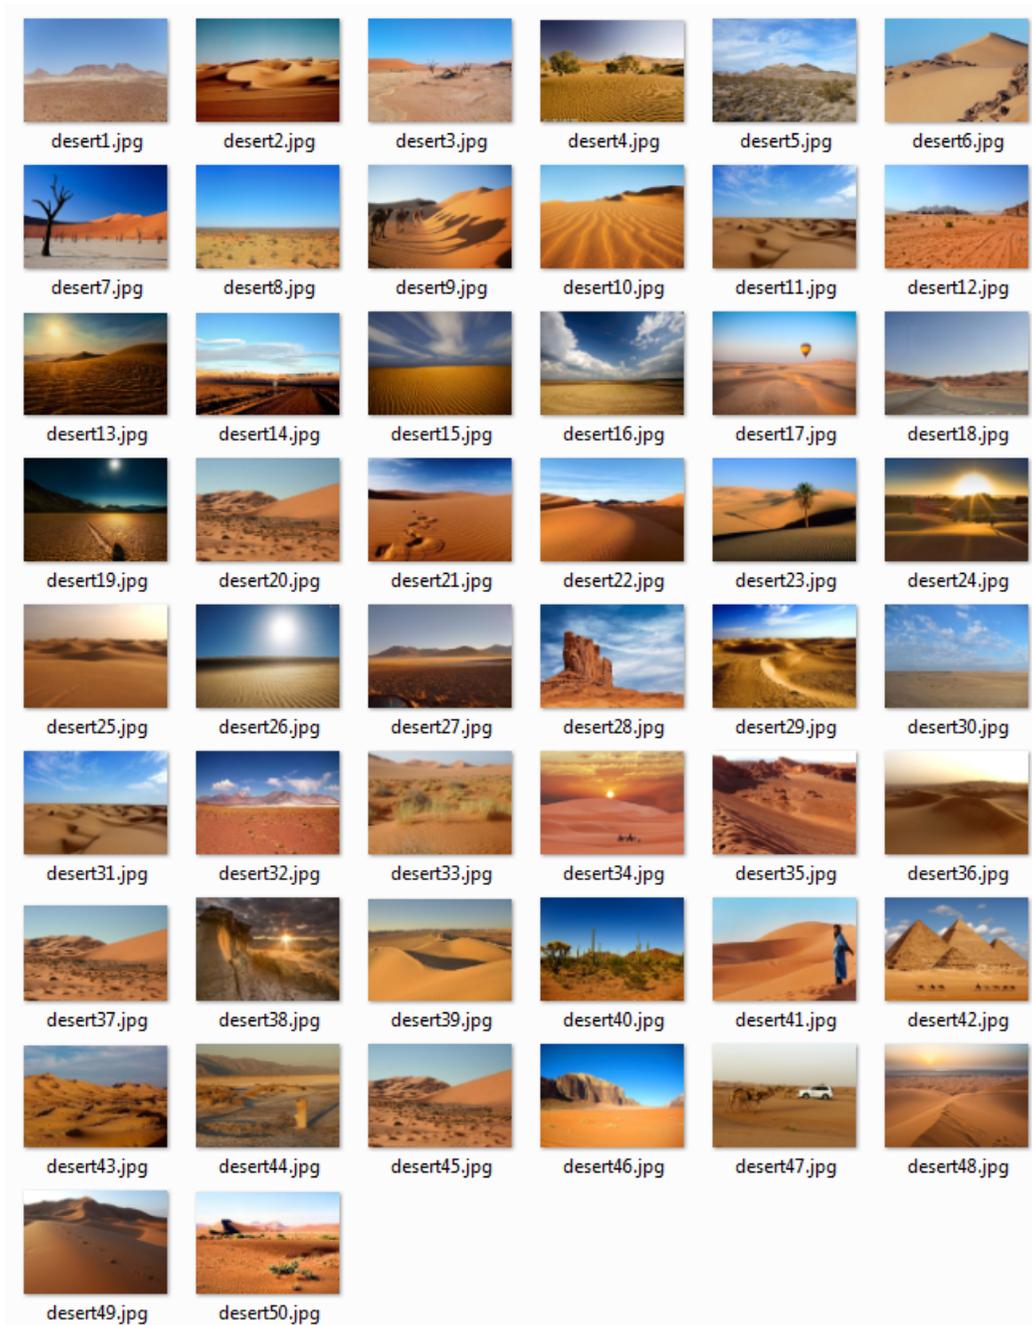


Figura 5.5: Imágenes usadas para la clase desierto

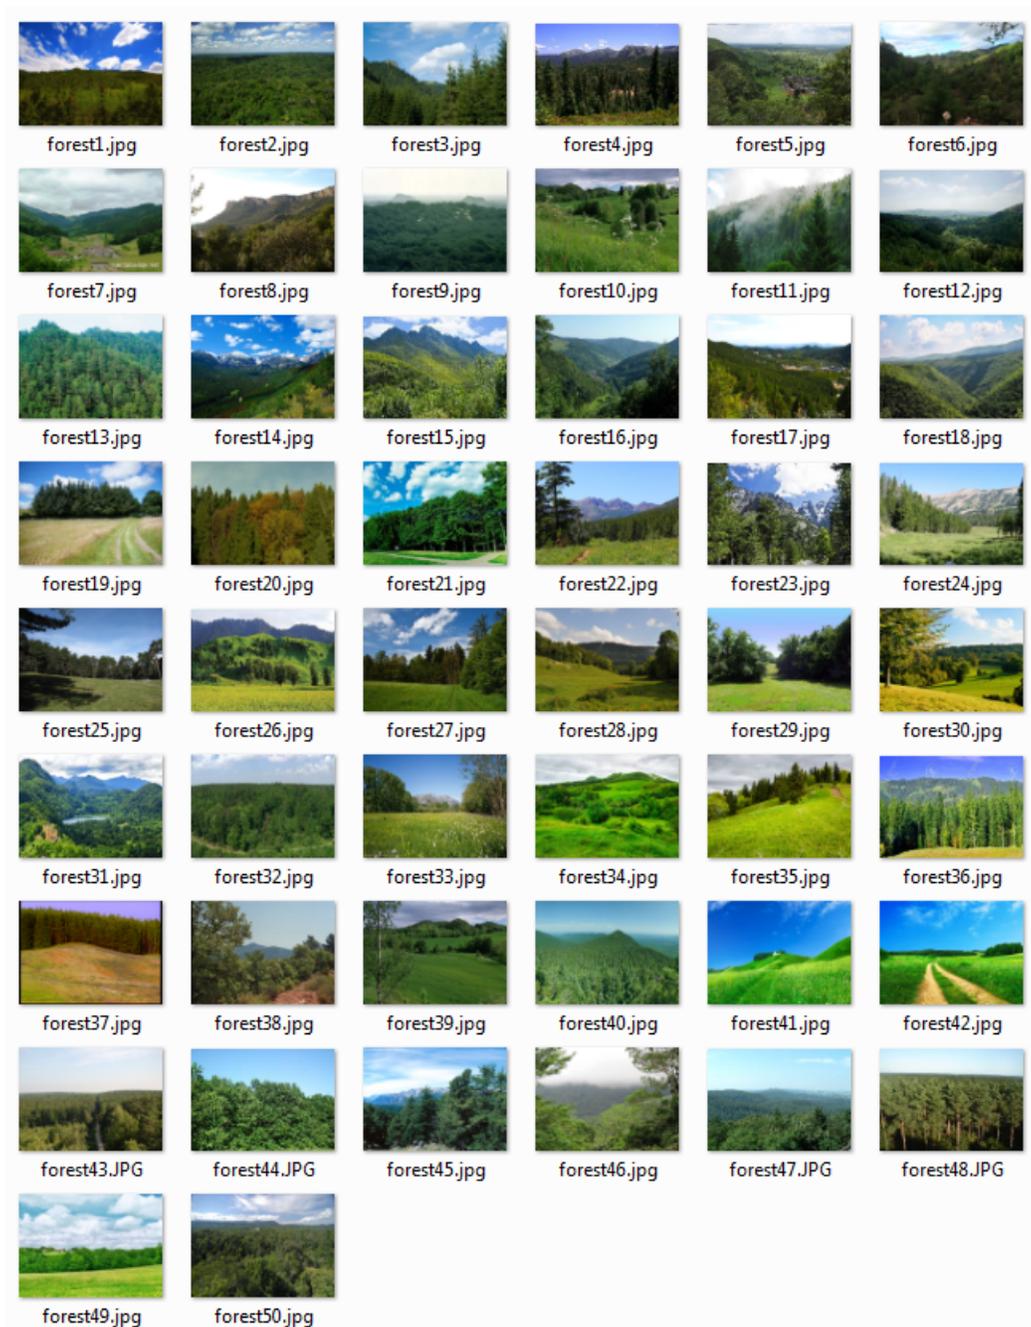


Figura 5.6: Imágenes usadas para la clase bosque

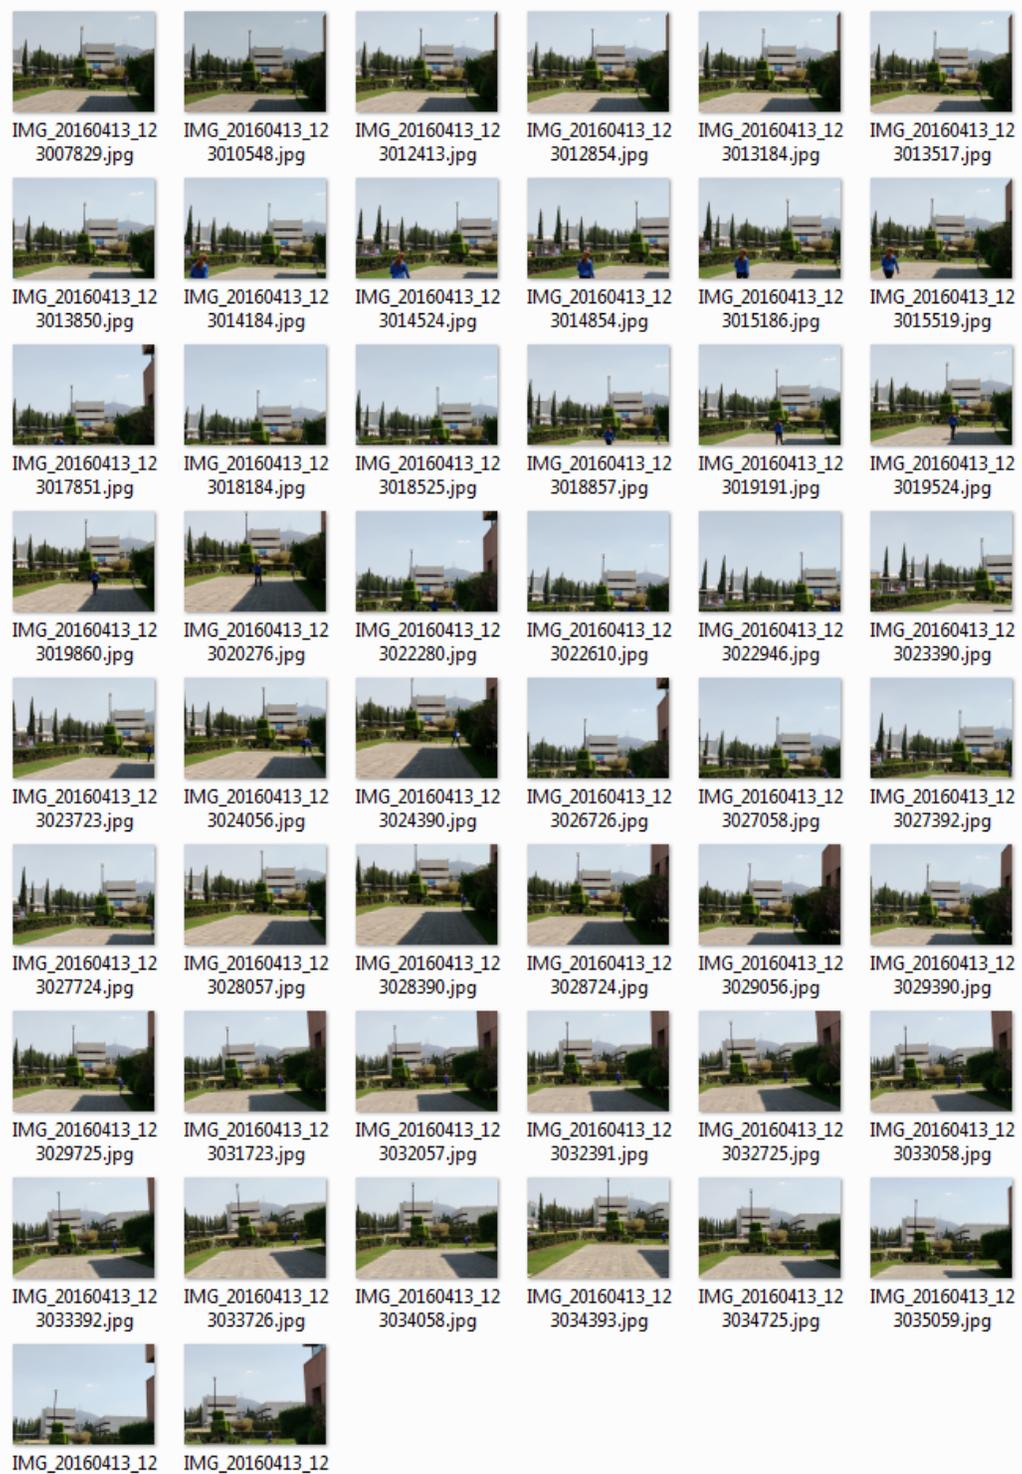


Figura 5.7: Imágenes usadas para la clase de prueba 1 ESCOM

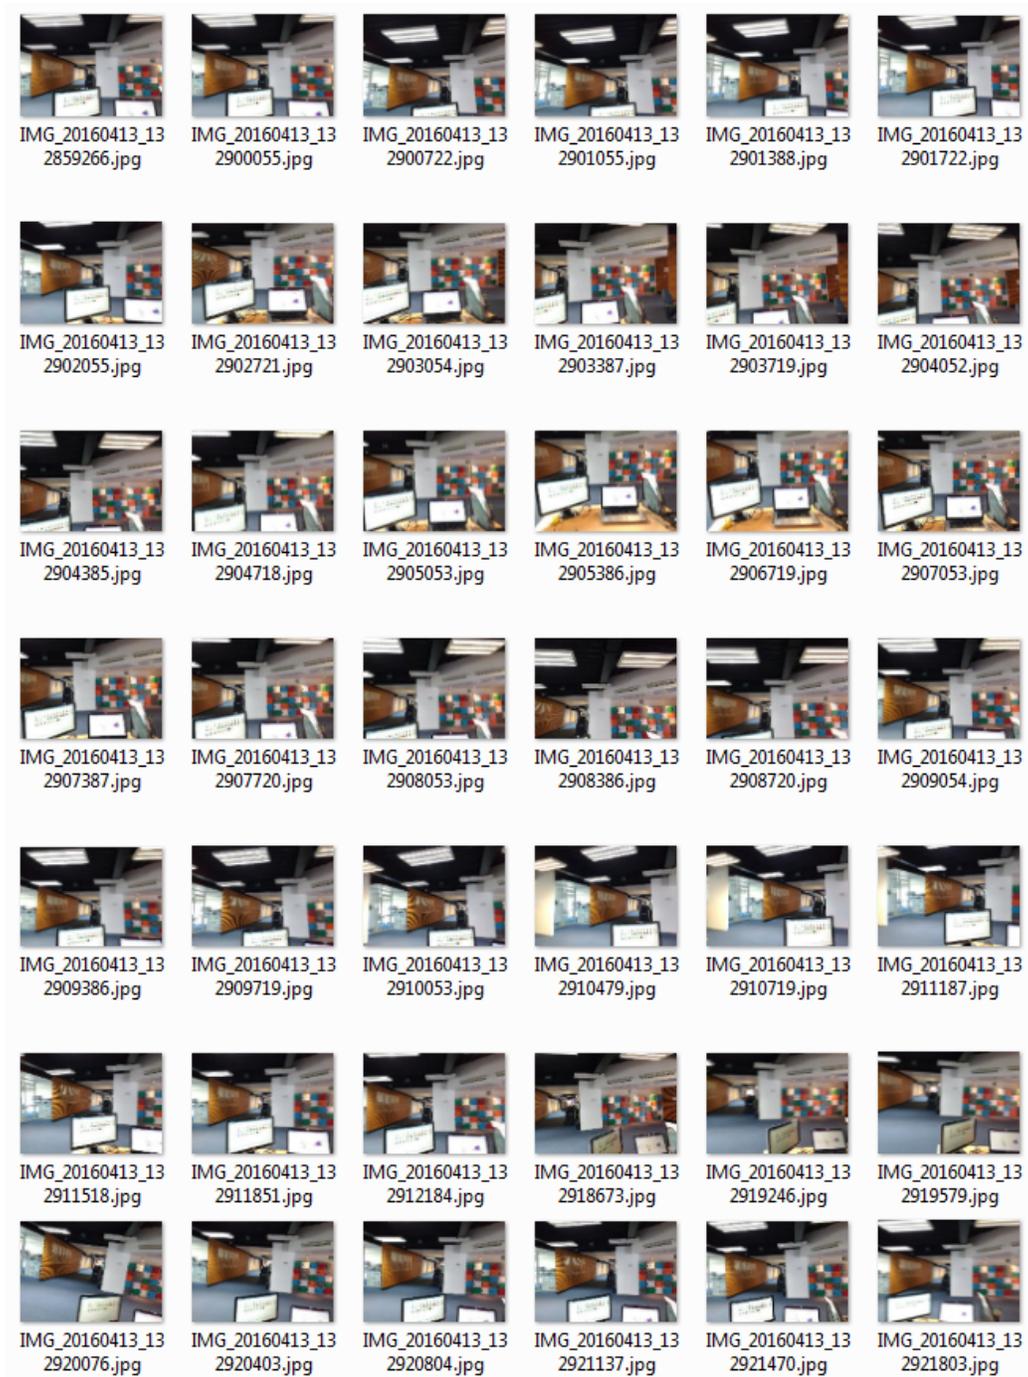


Figura 5.8: Imágenes usadas para la clase de prueba 2 CIC interior

Con el objeto de clarificar la visualización de los resultados se han removido todas las zonas componentes de cada patrón convencional, quedando únicamente el punto resultante de la suma vectorial realizada, y se ha agregado un cascarón exclusivamente representativo del posible volumen que cada clase formaría.

Aunque el objetivo actual es separar las clases playa, desierto y bosque, se hicieron pruebas con otras clases adicionales, las cuales corresponden a las clases de prueba "ESCOM" y "CIC interior". Como se puede ver cada tipo de escena genera un cúmulo cuya forma es de tipo espigada.

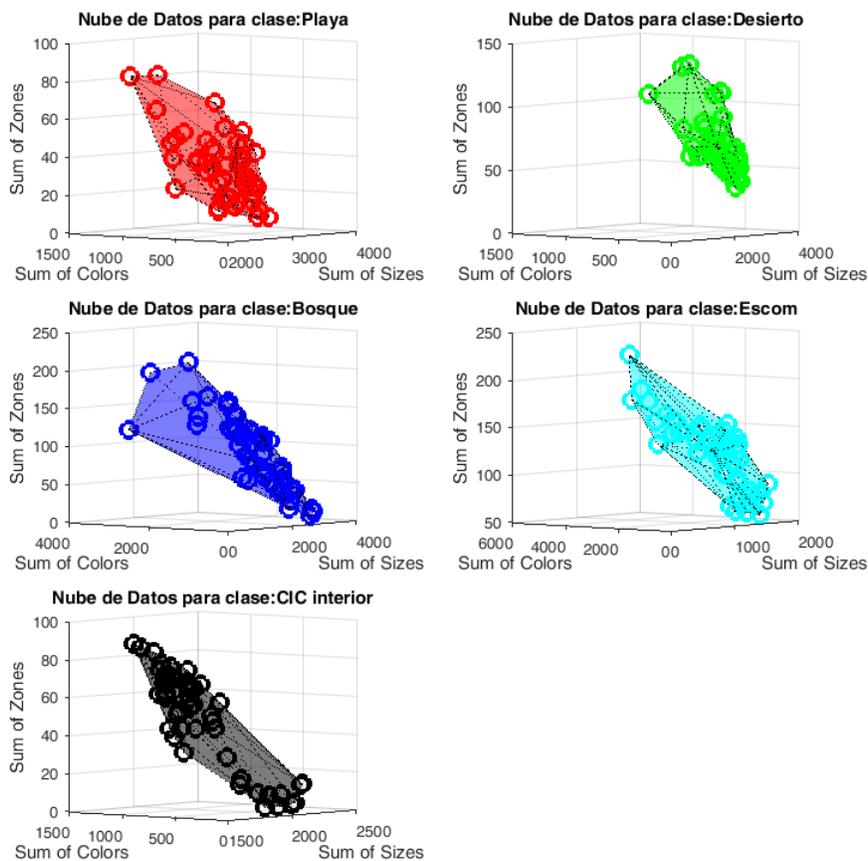


Figura 5.9: Cúmulos resultantes para varias clases

Con los cúmulos de datos puestos en el mismo espacio, vemos que el cascarón (*convex hull*) que forma cada clase tiene cierta intersección entre una clase y otra, que en conjunto forman el espacio contextual para este grupo de imágenes.

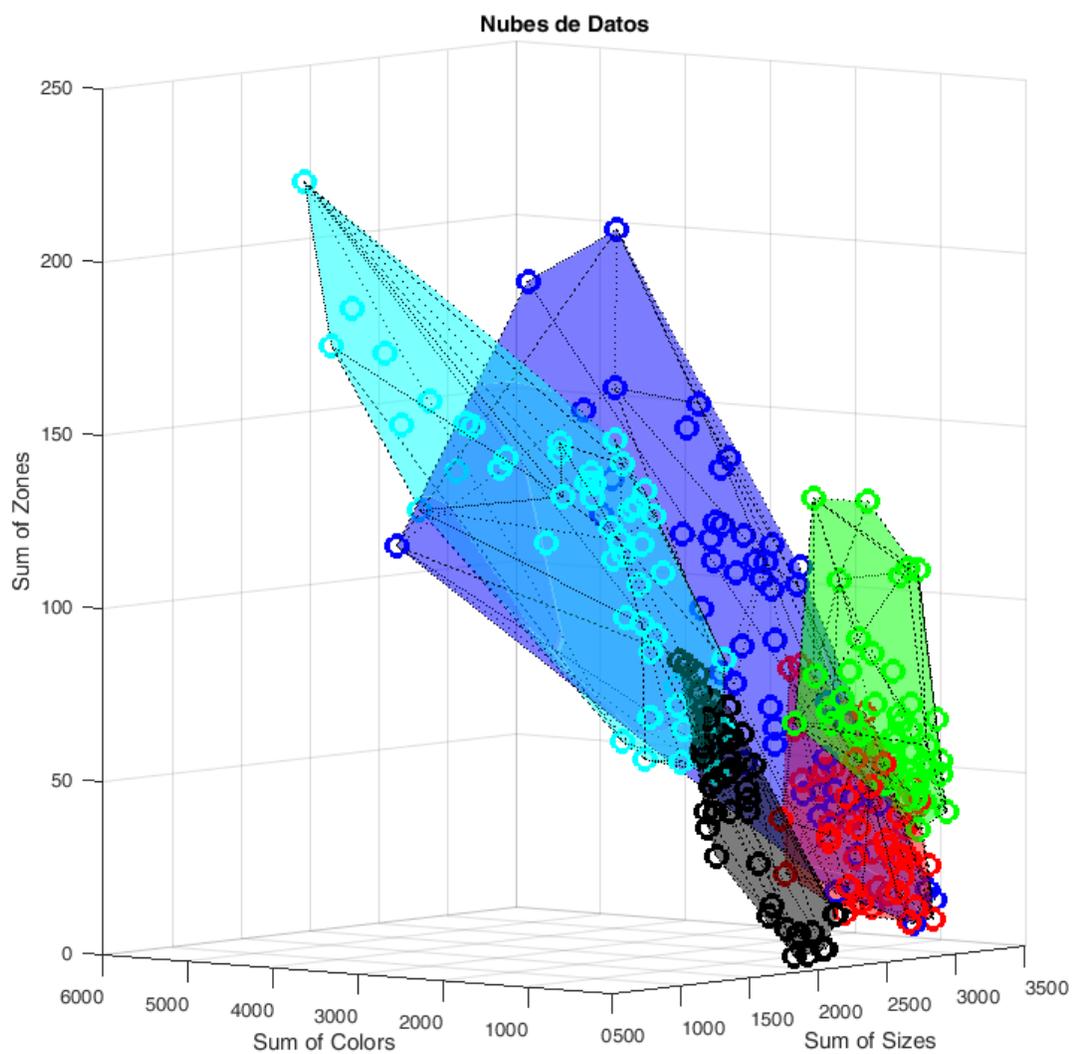


Figura 5.10: Cúmulos resultantes para varias clases en el mismo espacio

5.3. Del sistema de clasificación

A efectos de poder asignar una categoría a las imágenes procesadas por el sistema, los patrones convencionales (con dimensionalidad y significado de atributos fijo) generados fueron introducidos en una red neuronal y varios sistemas de agrupamiento no supervisados.

5.3.1. Sistemas de clasificación supervisada

RNA

Como primer clasificador se ha tomado una red neuronal de perceptrones con función de activación sigmoideal, de 3 capas con 3 nodos de entrada, 16 en la capa intermedia y en la capa de salida un número de nodos acorde a la cantidad de clases a clasificar, la cual ha sido entrenada con el algoritmo de retropropagación (*back propagation*).

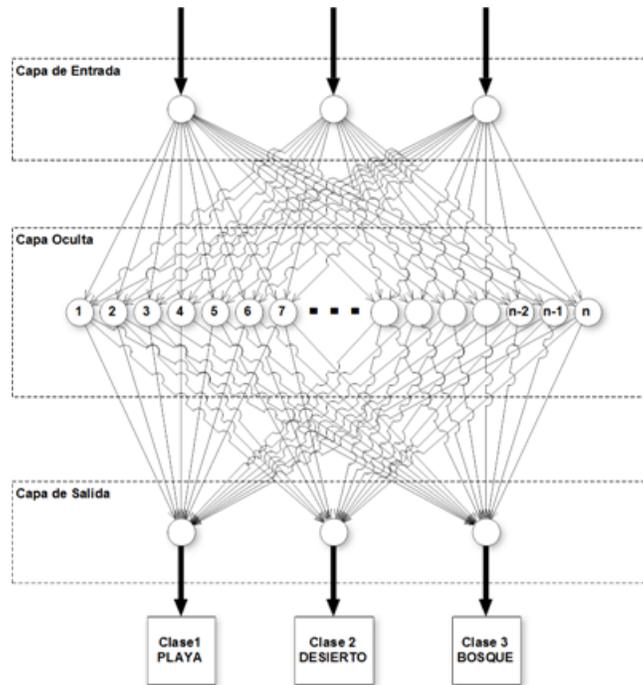


Figura 5.11: Arquitectura de la red neuronal usada

Experimento 1

Para el experimento 1, se clasificaron 3 grupos de datos correspondientes a las clases: "Playa", "Desierto" y "Bosque"; En la gráfica podemos ver los datos que fueron introducidos a la red neuronal.

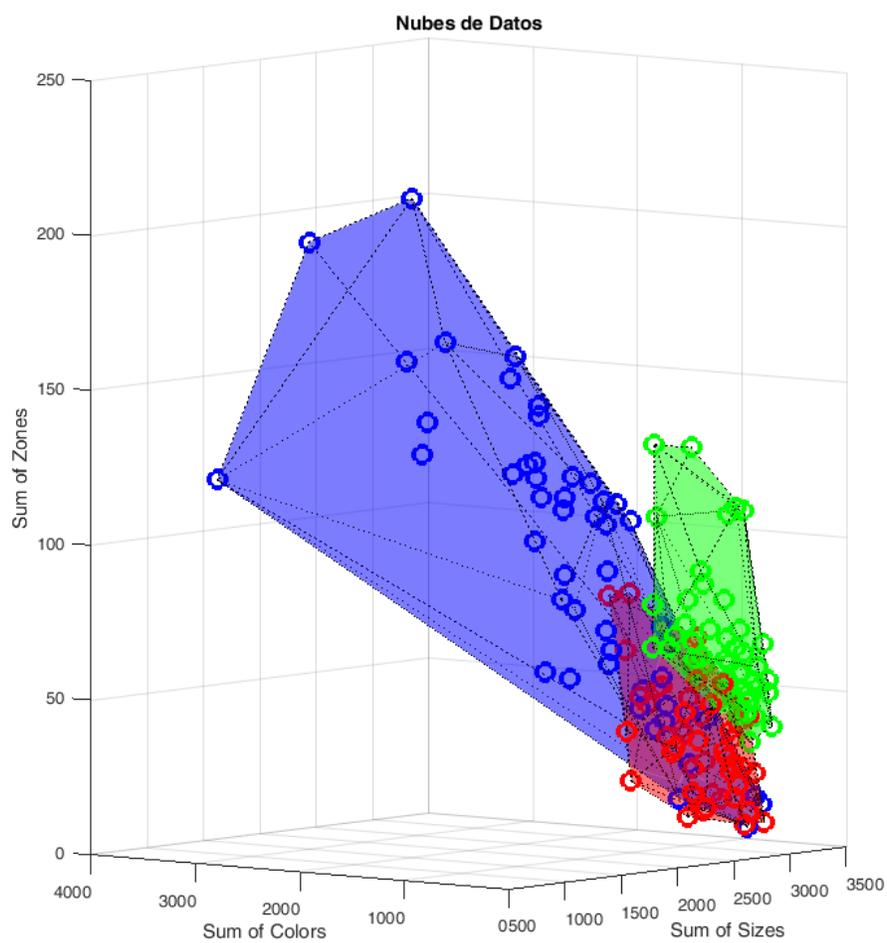


Figura 5.12: Nubes de datos para las clases elegidas

Como resultado del entrenamiento y evaluación se obtuvieron los valores de activación para cada una de las neuronas de salida. Los cuales se muestran en la siguiente figura donde eje horizontal nos indica el número de patrón en cuestión, correspondiendo del 1 al 50 a la clase "Playa", del 51 al 100 a la clase "Desierto" y del 101 al 150 a la clase "Bosque".

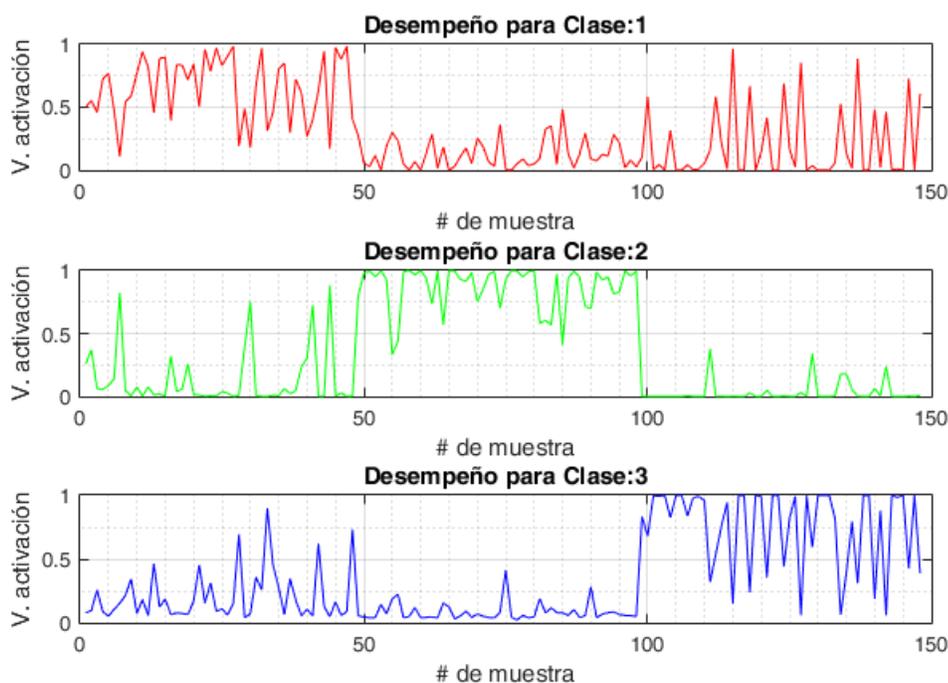
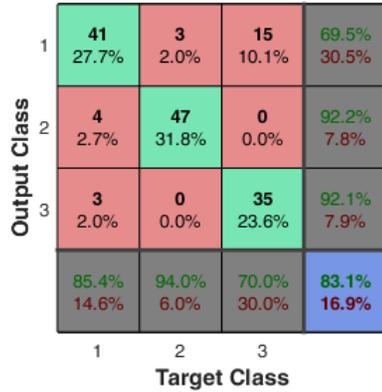


Figura 5.13: Salida de neuronas y los patrones aplicados

Precisión y Recuerdo

Se hicieron 10 evaluaciones conservando la misma arquitectura para 20,000 épocas las cuales arrojaron un conjunto de matrices de confusión como la que se muestra en la figura 5.14, de dichas matrices se calcularon los valores promedio de exactitud (*accuracy*), precisión, recuerdo (*recall*), así como la desviación estándar correspondiente, que posteriormente derivaron en la tabla 5.3.

ROUNDED OUTPUTS Confusion Matrix



	Épocas	20,000
Param		
Accuracy		82.5% ± 2.19%
Precision		84% ± 13%
Recall		83% ± 12%

Figura 5.14: Matriz de confusión resultante

Tabla 5.3: Resultados de la red neuronal para los patrones introducidos

Por otra parte para cada uno de los experimentos el comportamiento de la función de error fue el mostrado en la figura 5.15.

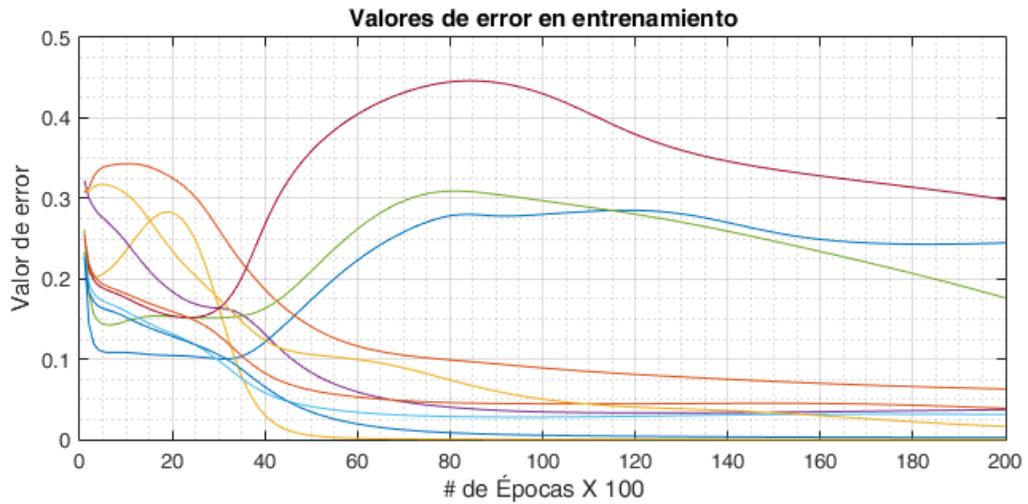


Figura 5.15: Evolución del error durante entrenamiento

Experimento 2

Para el experimento 2, se clasificaron 4 grupos de datos correspondientes a las clases: "Playa", "Desierto" y "Bosque", en la gráfica podemos ver los datos que fueron introducidos a la red neuronal.

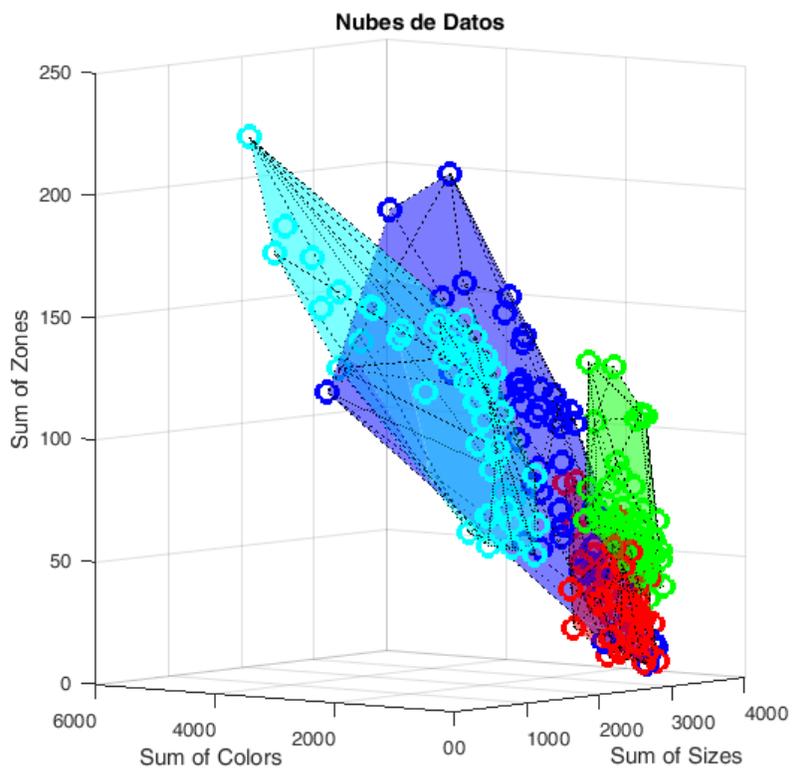


Figura 5.16: Nubes de datos para las clases elegidas

Como resultado del entrenamiento y evaluación obtuvimos los valores de activación para cada una de las neuronas de salida. Los cuales se muestran en la siguiente figura donde eje horizontal nos indica el número de patrón en cuestión, donde del 1 al 50 corresponden a la clase "Playa", del 51 al 100 a la clase "Desierto", del 101 al 150 a la clase "Bosque" y del 151 al 200 a la clase "Escom".

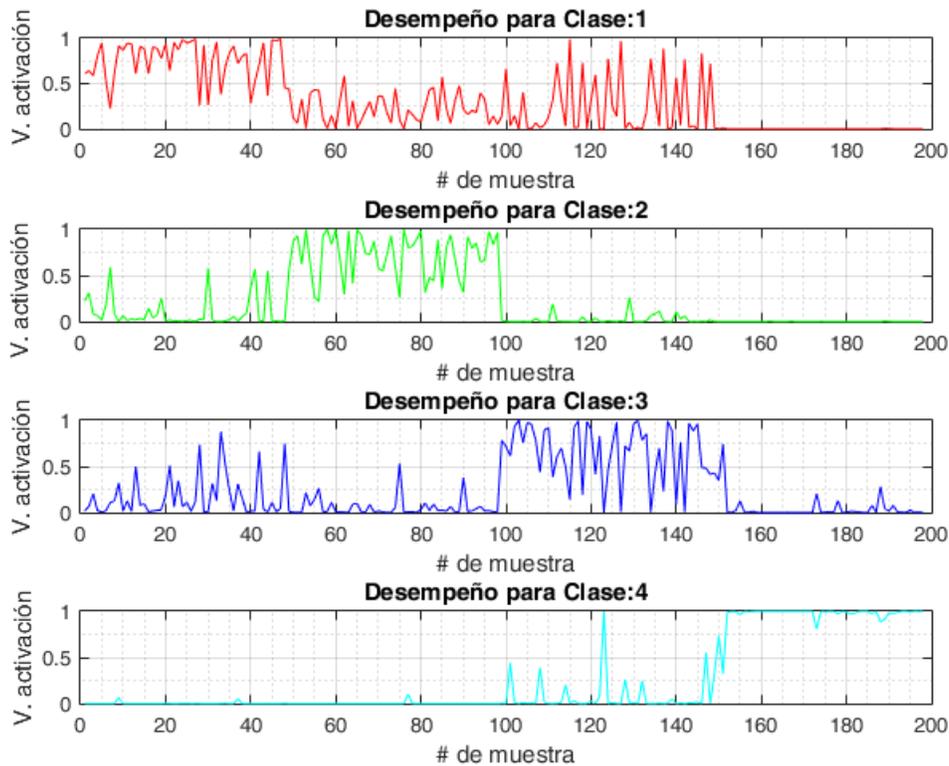


Figura 5.17: Salida de neuronas y los patrones aplicados

Precisión y Recuerdo

Se hicieron 10 evaluaciones conservando la misma arquitectura para 20,000 épocas las cuales arrojaron un conjunto de matrices de confusión como la que se muestra en la figura 5.18, de dichas matrices se calcularon los valores promedio de exactitud (*accuracy*), precisión, recuerdo (*recall*), así como la desviación estándar correspondiente, que posteriormente derivaron en la tabla 5.4..

ROUNDED OUTPUTS Confusion Matrix

Output Class	1	42 21.2%	10 5.1%	17 8.6%	1 0.5%	60.0% 40.0%
	2	3 1.5%	39 19.7%	0 0.0%	0 0.0%	92.9% 7.1%
	3	3 1.5%	1 0.5%	31 15.7%	1 0.5%	86.1% 13.9%
	4	0 0.0%	0 0.0%	2 1.0%	48 24.2%	96.0% 4.0%
		87.5% 12.5%	78.0% 22.0%	62.0% 38.0%	96.0% 4.0%	80.8% 19.2%
	1	2	3	4		
	Target Class					

	Épocas	20,000
Param		
Accuracy		82.32% ± 2.28%
Precision		84% ± 14%
Recall		82% ± 13%

Figura 5.18: Matriz de confusión resultante

Tabla 5.4: Resultados de la red neuronal para los patrones introducidos

Por otra parte para cada uno de los experimentos el comportamiento de la función de error fue el siguiente:

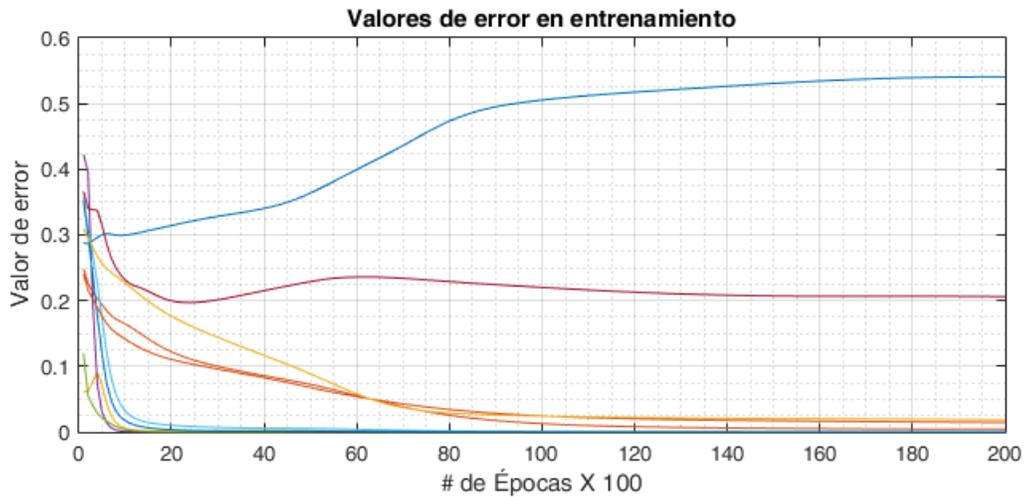


Figura 5.19: Evolución del error durante entrenamiento

Experimento 3

En este experimento, se clasificaron 5 grupos de datos correspondientes a las clases: "Playa", "Desierto", "Bosque", "Escom" y "CIC interior" en la gráfica podemos ver los datos que fueron introducidos a la red neuronal.

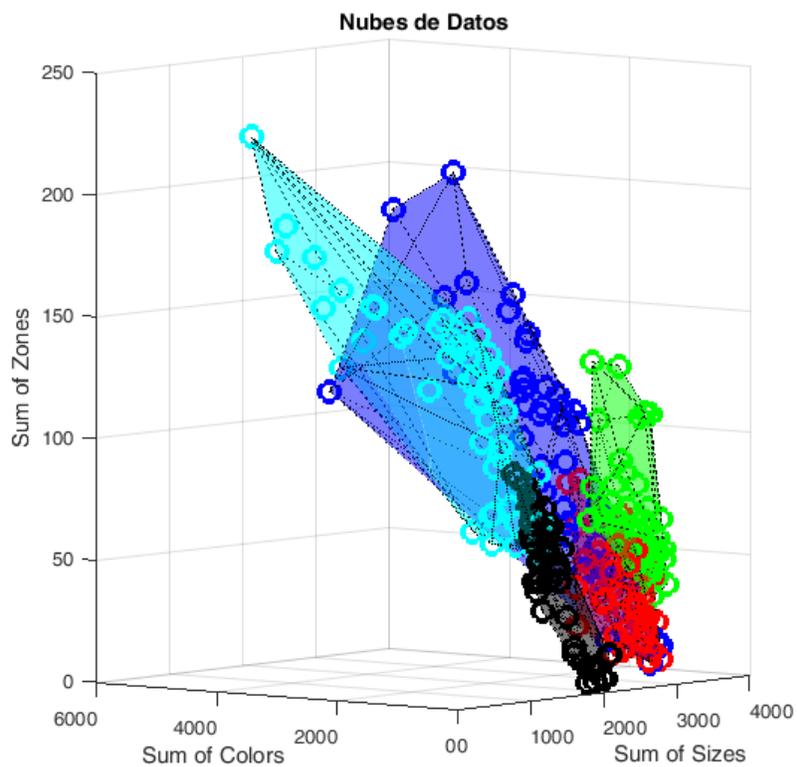


Figura 5.20: Nubes de datos para las clases elegidas

Como resultado del entrenamiento y evaluación obtuvimos los valores de activación para cada una de las neuronas de salida. Los cuales se muestran en la siguiente figura donde eje horizontal nos indica el número de patrón en cuestión, donde del 1 al 50 corresponden a la clase "Playa", del 51 al 100 a la clase "Desierto", del 101 al 150 a la clase "Bosque", del 151 al 200 a la clase "Escom" y de la 201 a la 250 a la clase "CIC interior"

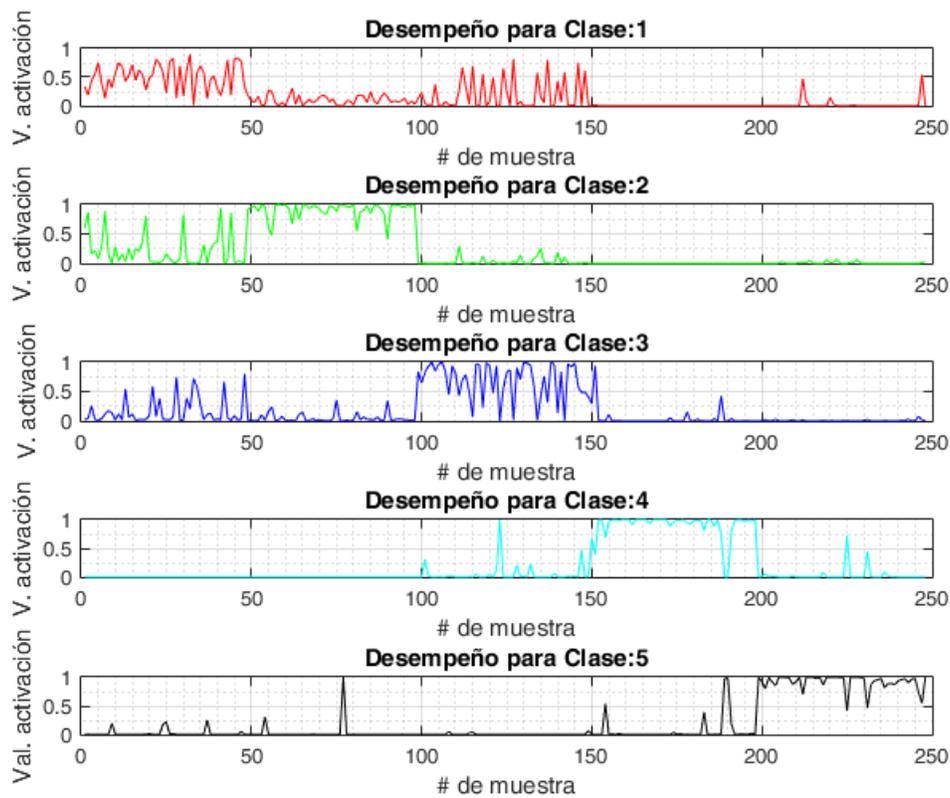
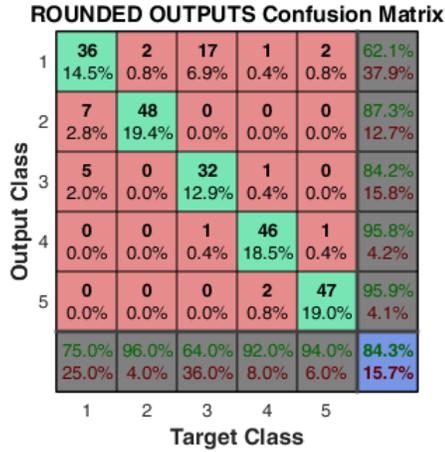


Figura 5.21: Salida de neuronas y los patrones aplicados

Precisión y Recuerdo

Se hicieron 10 evaluaciones conservando la misma arquitectura para 20,000 épocas las cuales arrojaron un conjunto de matrices de confusión como la que se muestra en la figura 5.22, de dichas matrices se calcularon los valores promedio de exactitud (*accuracy*), precisión, recuerdo (*recall*), así como



	Épocas	20,000
Param		
Accuracy		85.28 % ± 1.31 %
Precision		86 % ± 13 %
Recall		85 % ± 12 %

Figura 5.22: Matriz de confusión resultante Tabla 5.5: Resultados de la red neuronal para los patrones introducidos

la desviación estándar correspondiente, que posteriormente derivaron en la tabla 5.5

Por otra parte para cada uno de los experimentos el comportamiento de la función de error fue el siguiente:

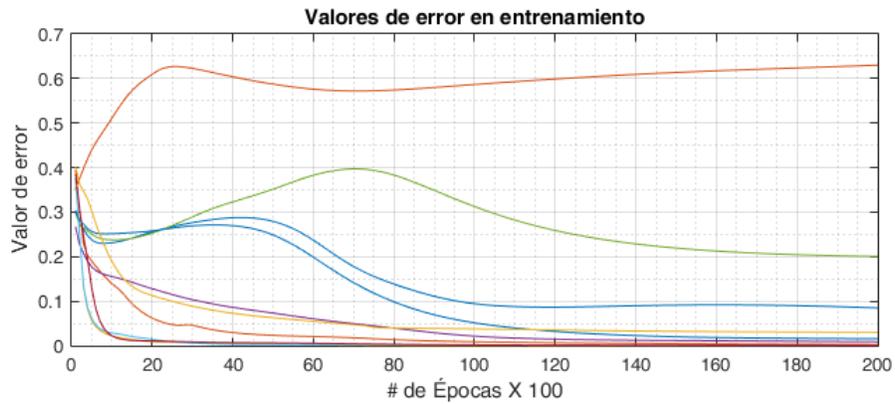


Figura 5.23: Evolución del error durante entrenamiento

Como conclusion de este experimento, podemos ver que el objetivo de clasificación se logra de manera adecuada aun cuando existe traslape entre ciertas clases.

5.4. De los algoritmos de agrupamiento no supervisado

5.4.1. Fuzzy C-Means

Las nubes de datos se procesaron con el algoritmo *fuzzy c-means* (FCM) obteniéndose los siguientes resultados:

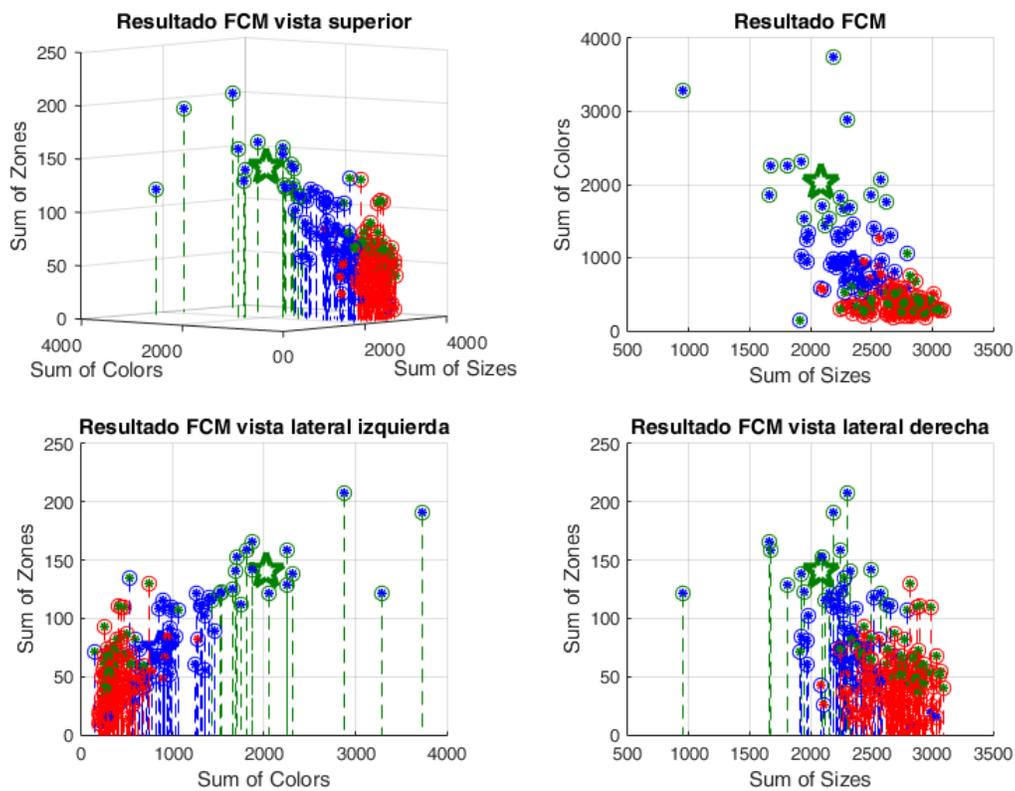


Figura 5.24: Resultados usando Fuzzy C-Means

Los parámetros usados fueron $C = 3$ y $m = 2$.

La matriz de confusión obtenida para este algoritmo es la siguiente, donde además podemos ver que el valor de accuracy es de 48.6 %

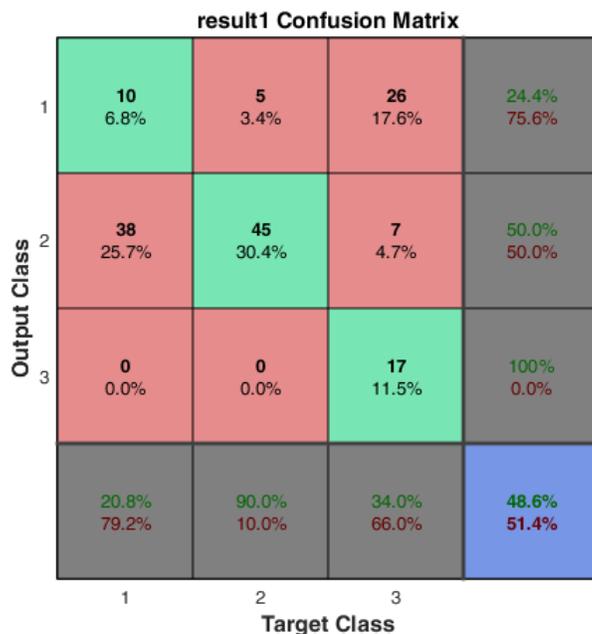


Figura 5.25: Resultados usando Fuzzy C-Means

Se utilizaron el PC, coeficiente de partición y PE entropía de partición, aplicados a las particiones obtenidas por el algoritmo FMC arroja las siguientes gráficas.

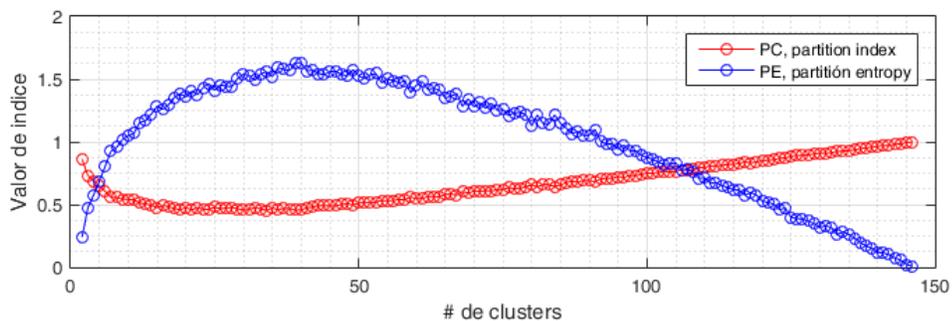


Figura 5.26: Resultados del PC y PE para FCM

5.4.2. Possibilistic C-Means

Las nubes de datos se procesaron con el algoritmo *possibilistic c-means* (PCM) obteniéndose los siguientes resultados:

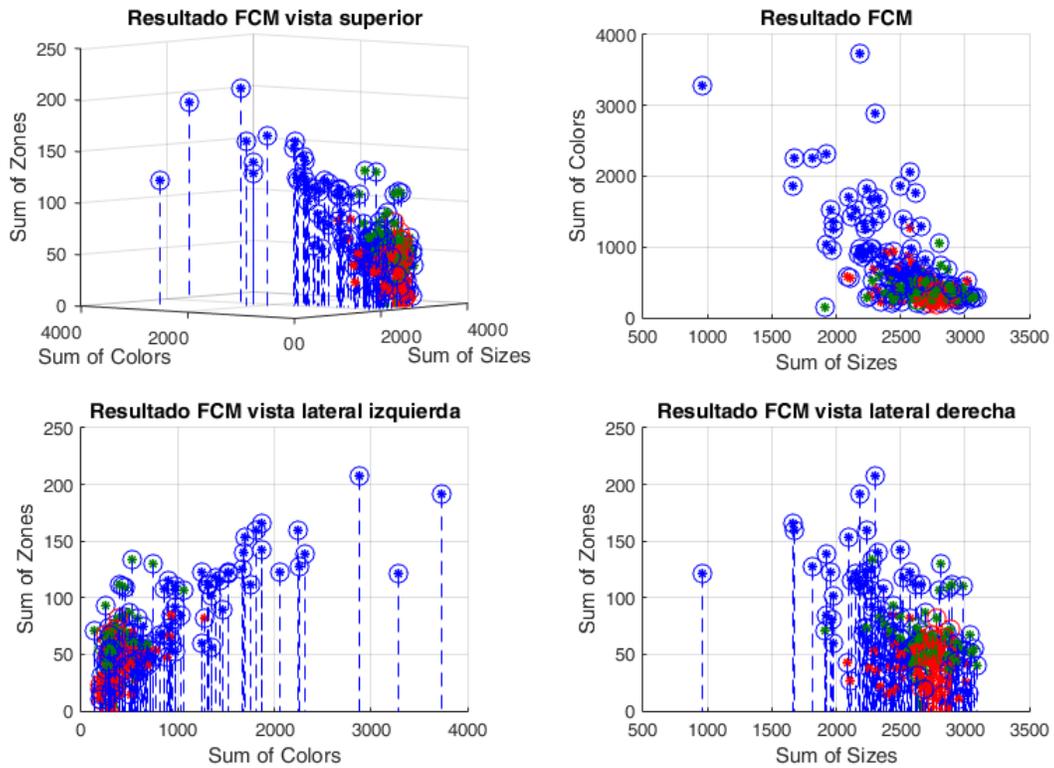


Figura 5.27: Resultados usando Possibilistic C-Means

De los resultados podemos ver que dada la distribución de los datos el algoritmo converge al mínimo global que genera la superposición de los clústers, lo cual es un problema común en el uso de este algoritmo.

La matriz de confusión obtenida para este algoritmo es la siguiente, donde además podemos ver que el valor de accuracy es de 45.9 %

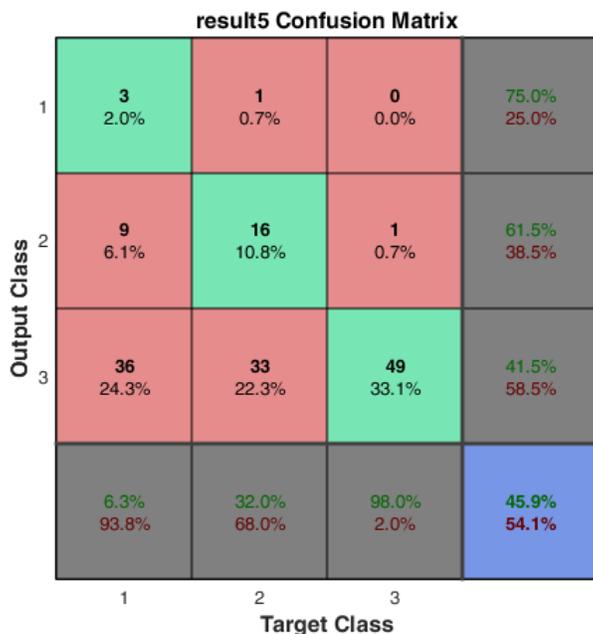


Figura 5.28: Resultados usando Possibilistic C-Means

Se utilizaron el PC, coeficiente de partición y PE entropía de partición, aplicados a las particiones obtenidas por el algoritmo PMC arroja las siguientes gráficas.

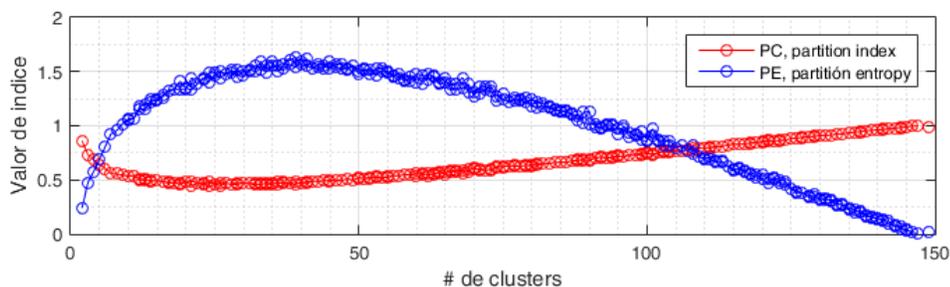


Figura 5.29: Resultados del PC y PE para PCM

5.4.3. Gustafson Kessel

Las nubes de datos se procesaron con el algoritmo Gustafson Kessel obteniéndose los siguientes resultados:

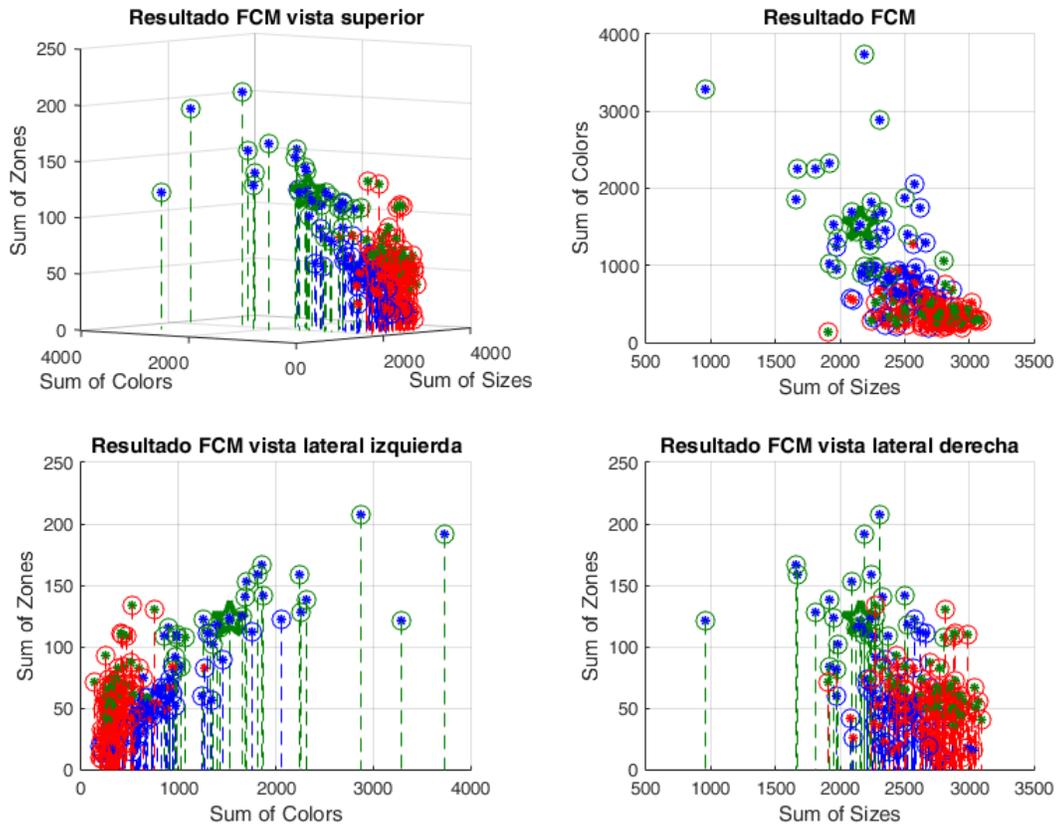


Figura 5.30: Resultados usando Gustafson Kessel

La matriz de confusión obtenida para este algoritmo es la siguiente, donde además podemos ver que el valor de exactitud es de 68.2%

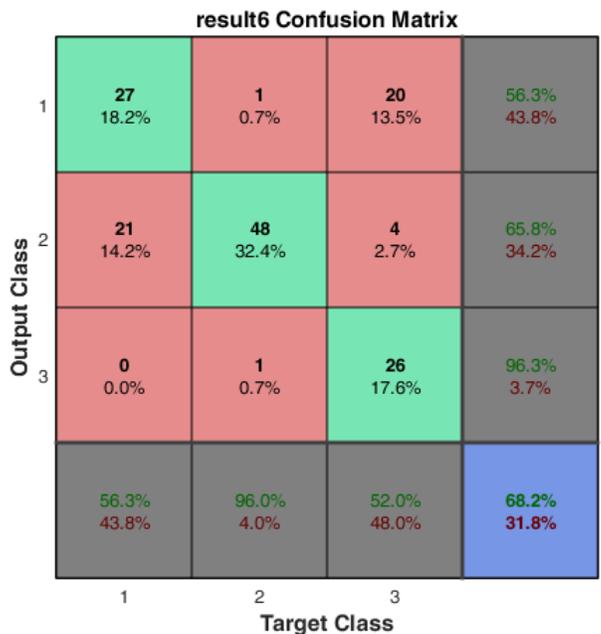


Figura 5.31: Resultados usando Gustafson Kessel

Se utilizaron el PC, coeficiente de partición y PE entropía de partición, aplicados a las particiones obtenidas por el algoritmo Gustafson Kessel arroja las siguientes gráficas.

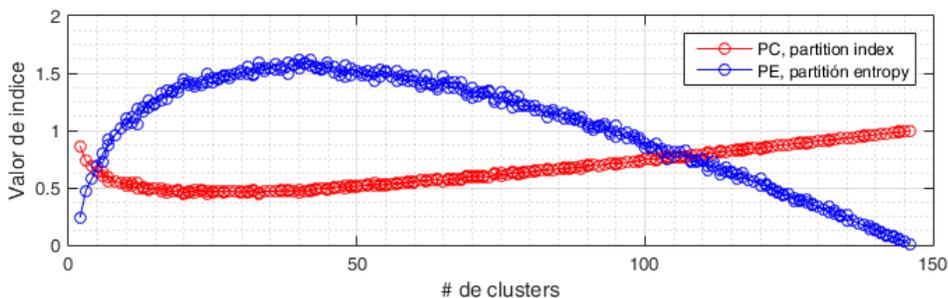


Figura 5.32: Resultados del PC y PE para algoritmo Gustafson Kessel

5.4.4. Agrupamiento Hiper cónico (Dancing Cones)

Las nubes de datos se procesaron con el algoritmo de los conos danzantes obteniéndose los siguientes resultados:

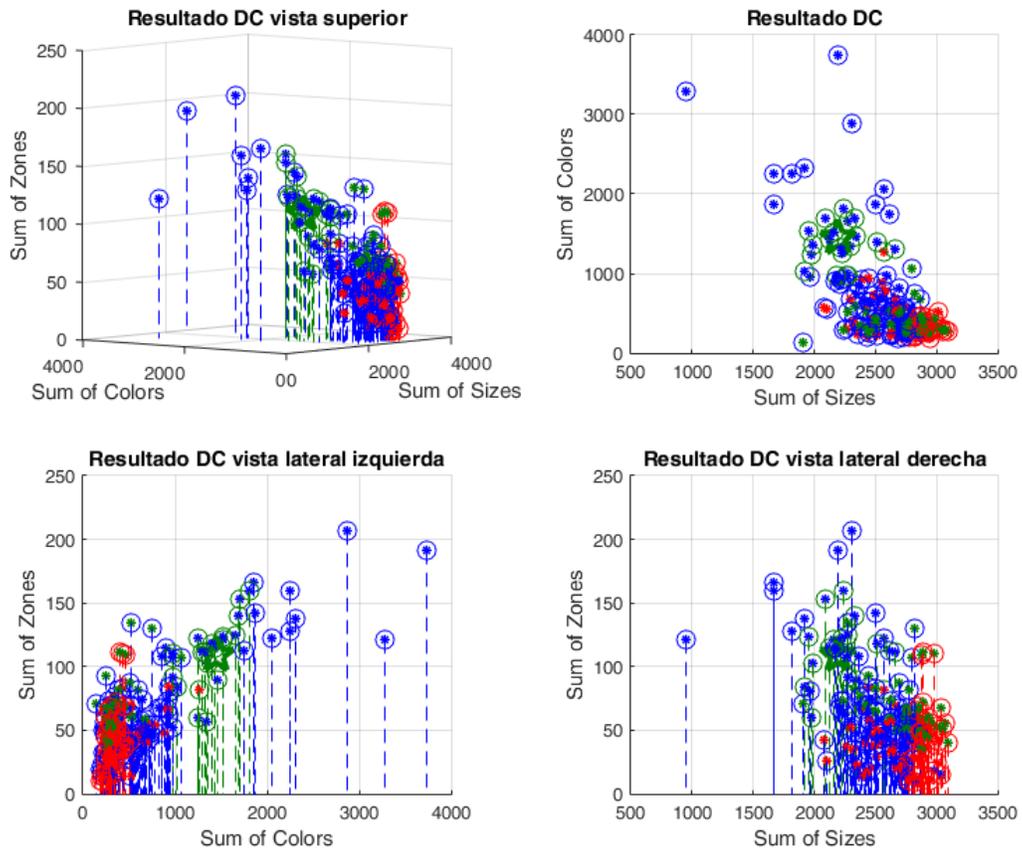


Figura 5.33: Resultados usando conos danzantes

La matriz de confusión obtenida para este algoritmo es la siguiente, donde además podemos ver que el valor de exactitud es del 53.4%

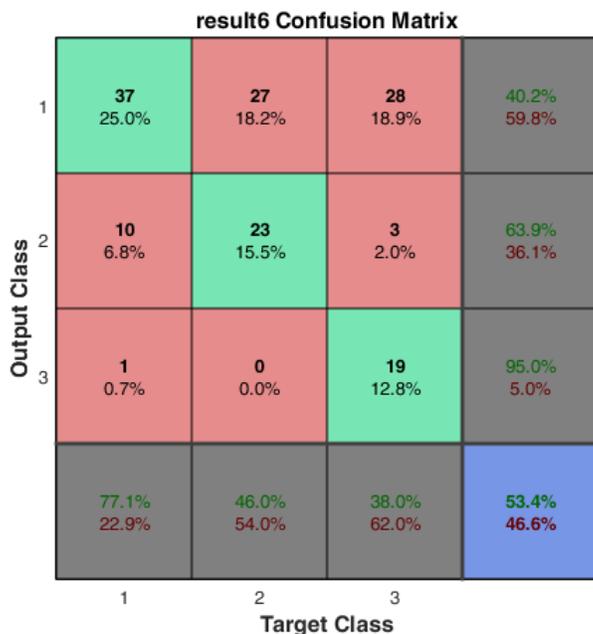


Figura 5.34: Resultados usando Conos Danzantes

Se utilizaron el PC, coeficiente de partición y PE entropía de partición, aplicados a las particiones obtenidas por el algoritmo Conos Danzantes arroja las siguientes gráficas.

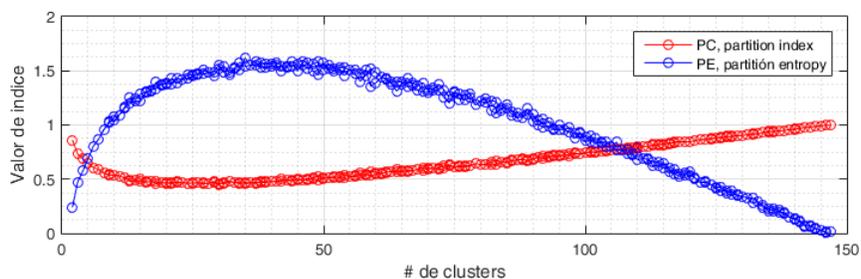


Figura 5.35: Resultados del PC y PE para algoritmo Conos Danzantes

5.4.5. Sumario de algoritmos no supervisados

De los resultados se puede ver que los algoritmos no supervisados tienen un mal desempeño, la razón de esto es que cada algoritmo hace asunciones acerca de la topología de los datos y cuando estos no coinciden con dicha topología los resultados tienden a ser erróneos con respecto a una comparativa supervisada.

El algoritmo de Gustafson Kessel asume que los datos tienen forma elíptica, la cual es más parecida a la que tienen los cúmulos de datos obtenidos, debido a esto es que se obtiene un mejor desempeño, lo cual se muestra en la siguiente tabla comparativa.

Algoritmo	Accuracy
<i>Fuzzy C-Means</i>	48.6 %
<i>Possibilistic C-Means</i>	45.8 %
<i>Gustafson Kessel</i>	68.2 %
<i>Hyperconic Clustering</i>	53.4 %

Tabla 5.6: Comparativa de accuracy para los 4 algoritmos usados

5.5. Tiempos de ejecución

Para la comparación de los tiempos de ejecución, se considerará únicamente la fase de granulación de la imagen, dado que es la que más tiempo consume dentro del proceso general de clasificación. Entenderemos como fase de granulación el momento en el cual la imagen se ha cargado en memoria y terminará con la generación de la secuencia de zonas.

Al respecto de la medición, consideraremos el valor promedio de 10 ejecuciones y la variación que estas presentan, resultando en un tiempo consumido de: $1014 \pm 257ms$.

Realizando una comparativa con trabajos que hacen clasificación de imágenes tenemos la siguiente tabla, donde el valor tiempo de ejecución es comparado, sin embargo es importante guardar las proporciones adecuadas ya que no es posible hacer una comparación directa debido a motivos como son: el tamaño de las imágenes, arquitectura secuencial o paralela, las especificaciones del ordenador en el que se ejecuta la aplicación, entre otros.

Trabajo	Título	Clases	Tiempo		Tamaño de imagen	Exactitud	Precisión	Recuerdo	Usa contexto
			secuencial	paralelo					
1	MRF satellite image classification on GPU	3,4,5	104	1.09	1657 X 849				No
2	An efficient algorithm for Facial Image Classification		4			90 - 95 %			No
3	Online semantic mapping of urban environments					80.1			Sí
4	Real time semantic context labeling for image understanding	1,2,3	0.272	0.125					Si
5	Image context classification based on visual codebook	2 - >11		0.046	481 X 321		80.45	80.36	Sí
6	Granular computing for image classification based on their context	1 - >5		1.014	630 X 450	82.5	81	82	Sí

Tabla 5.7: Comparativa de tiempos de ejecución con otros trabajos

5.6. Discusión

El sistema granular arroja datos útiles para conformar nubes de datos susceptibles de clasificación o agrupamiento.

Para este estudio se eligieron tres tipos de imágenes o escenarios, las cuales pueden ser cambiadas dependiendo de la necesidad existente de manera sencilla, la eficiencia del resultado estará en función de la compacidad del cluster resultante para la nueva clase de imágenes y los traslapes que se produzcan con otras clases en el mismo espacio de representación.

Aunque los atributos elegidos proporcionaron una fuente de información aceptable (solapamiento ligero de clases), no sabemos si son los mejores atributos, para lo cual habría que hacer una evaluación exhaustiva de otras opciones como son el número de esquinas, o la suma de conectividad en bordes. Una mejora en el desempeño dependerá de si, en el nuevo espacio contextual generado por dichos atributos se producen cúmulos separables (sin traslapes).

De la misma manera, el sistema de representación contextual forma un espacio que muestra ser útil para la representación de imágenes. Aunque dado que aún existe cierto traslape entre clases, acorde a los puntos obtenidos, podemos decir que no es óptimo, sin embargo, es lógico que esto suceda dado que el punto de traslape está en las imágenes con pocas zonas donde el concepto no está muy detallado dando lugar a que otros conceptos igualmente no detallados compartan esa misma posición en el espacio contextual.

Cómo se puede ver por los resultados obtenidos, tenemos un desempeño en exactitud (*accuracy*) que ronda el 85 %, bajo el uso del paradigma granular en sistemas supervisados, por arriba del detector de peatones[1], y del sistema reflex[9] que están alrededor del 92 %, y una precisión de alrededor del 84 % comparable con el sistema de detección de cáncer[18].

Referente al agrupamiento no supervisado, vemos que el desempeño es bajo 68.2 %, sin embargo, esto es debido a que muchos de los algoritmos utilizados hacen suposiciones acerca de la morfología de los cúmulos de datos a agrupar, que en general suelen ser esféricos, elípticos o de alguna otra forma seleccionada, mientras que los cúmulos obtenidos son similares a espigas cur-

vadas; Los algoritmos usados tendrán un mal comportamiento a la hora de agrupar los datos aun cuando los clusters obtenidos sean válidos de acuerdo a los índices de validación de grupos usados pero no a la naturaleza real de los conceptos representados, una forma de remediar esto es a través del incremento en el número de grupos (*clusters*) y de los cuales asignaremos varios a un mismo tipo de familia.

Qué es lo que se hizo de nuevo comparado con lo del estado del arte

La diferencia con respecto a los sistemas existentes es la posibilidad de lograr la conectividad de gránulos usando operaciones lineales y con información puramente local. El sistema granular y el sistema de clasificación se mantienen separados lo cual permite trabajar de manera independiente ambas herramientas. El sistema granular no requiere entrenamiento para su funcionamiento, ni información semilla para realizar el entrenamiento de la red neuronal usada y finalmente no se requirió de un pre procesamiento adicional al ya hecho por el sistema granular.

Conclusiones

6.1. Conclusiones

Constatamos la efectividad del sistema granular para simplificar imágenes de contenido complejo y la consecuente obtención de un patrón del tipo PDSV. Se observó que el factor ϕ tiene un papel determinante en la cantidad de zonas y su correspondiente tamaño lo cual a su vez impacta calidad de los cúmulos de datos obtenidos.

El sistema de representación conceptual se muestra funcional para la conversión efectiva de patrones del tipo PDSV a PC, que permite enlazar los resultados del sistema granular con los sistemas de clasificación y/o agrupamiento (*clustering*) convencionales.

Al respecto de los clasificadores utilizados, el resultado arrojado por la red neuronal muestra una exactitud de clasificación aceptable aún cuando la topología de las clases muestran cierto traslape al nivel de representación del patrón convencional obtenido.

Es decir pudimos validar mediante la tarea de clasificación que los datos obtenidos mediante técnicas granulares son útiles.

En la parte no supervisada, se concluye que el algoritmo seleccionado debe tomar en cuenta la morfología de los cúmulos de datos para tener mejores resultados.

6.2. Aportaciones

Se define un sistema de abstracción de información que permite utilizar versiones representativas y reducidas de la entrada original, con lo cual se tiene una alternativa adicional para clasificar o agrupar imágenes de contenido complejo.

Se provee de un método para construir y representar información compleja a nivel conceptual en R3.

6.3. Limitaciones

De los resultados sabemos que el factor ϕ juega un papel determinante en la cantidad de zonas obtenidas, La principal limitación en el presente estudio es que el ajuste de este factor se hizo de manera manual.

6.4. Trabajo Futuro

El rumbo de este trabajo va hacia la creación de sistemas granulares que manejen información con contextos más complejos, para lo cual es necesario abordar los siguientes aspectos como trabajo futuro.

El factor de similitud ϕ es fijo, es necesario tener un mecanismo que lo genere de forma automática y auto adaptable que optimice la generación de zonas.

Para lo anterior se deben explorar propuestas tales como:

- Usar valores de ϕ dinámicos con respecto a la posición del gránulo en la capa que lo contiene. Ejemplo de ello podría ser dar mayor importancia a los valores centrales y discriminar las orillas.
- Usar valores de ϕ variables con respecto al nivel de la capa en la que está contenido el gránulo en cuestión.
- Utilizar solapamiento de datos de entrada entre gránulos para establecer cierta redundancia ante pixeles faltantes o dañados.

Al nivel de la calidad de los cúmulos, es necesario diseñar funciones de significancia de información, las cuales serán alimentadas por cada capa de la jerarquía, y asociarán un nivel de significancia de la información provista a cada una de las capas o niveles distintos resolución, que permitan seleccionar un ϕ y una capa óptima para proveer mayor calidad en el patrón final de salida.

Establecer un algoritmo de búsqueda de información en diferentes capas a diferentes resoluciones cuando la capa en cuestión no proporciona la información o el nivel de relevancia de la información para resolver el problema se podrá saltar una capa superior o inferior.

Apéndices

Apéndice A

Algoritmos de agrupamiento

A.1. Algoritmo Fuzzy C-means (FCM)

Dado un grupo de datos Z , seleccionar el número de grupos $1 < c < N$, el exponente de ponderación $m > 1$, la tolerancia para para terminar $\epsilon > 0$ y una matriz de norma inducida A . Inicializar la matriz de partición en forma aleatoria. Tal que $U^0 \in M_{fc}$.

Repetir para $l = 1, 2, \dots$

Paso 1. Calcular los prototipos (media):

$$v_i^{(l)} = \frac{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^m * z_k}{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^m}, 1 \leq i \leq c.$$

Paso 2. Calcular las distancias:

$$D_{ikA}^2 = (z_k - v_i^{(l)})^T A (z_k - v_i^{(l)}), 1 \leq i \leq c, 1 \leq k \leq N$$

Paso 3. Actualizar la matriz de partición:

Si $D_{ikA} \leq 0$ para $1 \leq i \leq c, 1 \leq k \leq N$,

$$\mu_{ik}^{(l)} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ikA}}{D_{jkA}}\right)^{2(m-1)}}$$

De otra forma:

$$\mu_{ik}^{(l)} = 0 \text{ si } D_{ikA} = 0, \text{ y } \mu_{ik}^{(l)} \in [0, 1] \text{ con } \sum_{i=1}^c \mu_{ik}^{(l)} = 1$$

Hasta que $\|U^{(l)} - U^{(l-1)}\| \leq \epsilon$.

A.2. Algoritmo Possibilistic C-Means (PCM)

Dado el conjunto Z y una buena partición inicial $U^{(0)} \in M_{pc}$, seleccionar el número de grupos $1 < c < N$, el exponente de ponderación $m > 1$, la tolerancia de terminación $\epsilon > 0$ y la matriz de norma inducida A . Estimar η_i utilizando:

$$\eta_i = \frac{\sum_{k=1}^N (\mu_{ik})^m D_{ikA}^2}{\sum_{k=1}^N (\mu_{ik})^m}$$

Repetir para $l = 1, 2, \dots$

Paso 1: Calcular los grupos prototipo (medios):

$$v_i^{(l)} = \frac{\sum_{k=1}^N (\mu_{ik})^{l-1} z_k}{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^m}, 1 \leq i \leq c$$

Paso 2 Calcular las distancias:

$$D_{ikA}^2 = (z_k - v_i^{(l)})^T A (z_k - v_i^{(l)}), 1 \leq i \leq c, 1 \leq k \leq N$$

Paso 3: Actualizar la matriz de partición

$$\mu_{ik}^{(l)} = \frac{1}{1 + \left(\frac{D_{ikA}}{\eta_i}\right)^{2l(m-1)}}, 1 \leq i \leq c, 1 \leq k \leq N$$

A.3. Algoritmo Dancing Cones (DC)

Dado el grupo de datos Z , seleccionar el número de grupos $1 < c < N$, los centros iniciales V^t , tolerancias de terminación $\epsilon > 0$ y una matriz de norma inducida A .

Paso 1: Calcular $s_1 = \text{abs}(\max(Z_x) - \min(Z_x))$ y $s_2 = \text{abs}(\max(Z_y) - \min(Z_y))$.

Paso 2: Calcular el radio de los hiperconos:

$$r_i = \frac{\sqrt{\sum_{l=1}^p s_l^2}}{c+1}$$

Paso 3: Calcular las funciones de membresía para cada uno de los hiperconos:

$$\mu_i = \begin{cases} 1 - \frac{D_{ikA}^2}{r_i} & \text{para } D_{ikA}^2 \leq r_i \\ 0 & \text{de otra forma} \end{cases} \quad (\text{A.1})$$

Paso 4: Calcular las distancias:

$$D_{ikA}^2 = (z_k - v_i^{(l)})^T A (z_k - v_i^{(l)}), 1 \leq i \leq c, 1 \leq k \leq N$$

Paso 5: Calcular los grupos prototipo (medios)

$$v_i^{(l)} = \frac{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^m z_k}{\sum_{k=1}^N (\mu_{ik}^{(l-1)})^m}, 1 \leq i \leq c$$

hasta que: $\|V^{(l)} - V^{(l-1)}\| \leq \epsilon$

Bibliografía

- [1] CHAN, Y.-M. Pedestrian detection using histograms of oriented gradients of granule feature. *2013 IEEE Intelligent Vehicles Symposium (IV)* (2013).
- [2] CHIN-TEN-LIN, C. G. L. *Neural Fuzzy Systems, a neuro-fuzzy synergism to intelligent systems*. Prentice Hall, One Lake street, Upper Saddle River, NJ, 07458., 1995.
- [3] FEI, X. Multigranular methods for retrieving thangka images. *Progress in informatics and computing (PIC), 2014 International Conference on* (2014).
- [4] GE CUI, X. W. A preliminary study using granular computing for remote sensing image segmentation involving roughness. *Proceedings Brain Informatics International Conference* (2012).
- [5] GUOJUN GAN, C. M., AND WU, J. *Data Clustering, Theory, Algorithms and Applications*. ASA SIAM, 3600 Market Street, 6th Floor, Philadelphia., 2007.
- [6] HONG HU, L. P. Perception granular computing in visual haze-free task. *Expert Systems with Applications 41 (2014) 2729–2741* (2014).
- [7] L. DUVAL, M. M. Image processing for materials characterization: issues, challenges and opportunities. *ICIP 2014* (2014).
- [8] MEHMET SEZGIN, B. S. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging* (2003).

- [9] NANDEDKAR, A. V. Supervised colour image segmentation using granular reflex fuzzy min max neural network. *Proc. SPIE 7546, Second International Conference on Digital Image Processing* (2010).
- [10] OLENA SCHUESSLER, D. L. Parallel training of artificial neural networks using multithreaded and multicore cpus. *ICANNGA 2011* (2011).
- [11] OTSU, N. A threshold selection method from gray-level histograms. *IEEE Transactions on systems, man and cybernetics* (1979).
- [12] PAL, S. K. Computational theory perception (ctp), rough-fuzzy uncertainty analysis and mining in bioinformatics and web intelligence: A unified framework. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (2010).
- [13] PAL, S. K. Using grcc for color image segmentation based on the combination of color and texture. *Biometric Recognition Volume 9428 of the series Lecture Notes in Computer Science pp 728-735* (2015).
- [14] PEDRYCZ, W. Clustering granular data and their characterization with information granules of higher type. *Annual Conference of the North American Fuzzy Information Processing Society* (2001).
- [15] PEDRYCZ, W. Granular computing: An introduction. *IEEE Transactions on fuzzy systems* (2015).
- [16] PEDRYCZ, W. Hierarchical granular clustering: An emergence of information granules of higher type and higher order. *IEEE Transactions on fuzzy systems* (2015).
- [17] RAFAEL C. GONZALEZ, R. E. W. *Digital Image Processing*. Prentice Hall, Upper Saddle River, New Jersey 07458, 2001.
- [18] ROSELIN, R. Mammogram image segmentation using granular computing based on rough entropy. *Proceedings of the International Conference on Pattern Recognition, Informatics and Medical Engineering , March 21-23, 2012* (2012).
- [19] SMITH, A. R. Color gamut transform pairs. *SIGGRAPH 78 Conference Proceedings* (1978).

- [20] THEODORIDIS, S. *Pattern Recognition*. Elsevier, 30 Corporate Drive, Suite 400, Burlington, MA, 01803 USA., 2009.
- [21] YAO, Y. Granular computing: Past, present and future. *2008 IEEE International Conference on Granular Computing* (2008).
- [22] YAO, Y. Y. Granular computing. *2004 Proceedings of The 4th Chinese National Conference on Rough Sets and Soft Computing* (2004).