

MÁSTER EN INGENIERÍA DE SISTEMAS Y CONTROL
DEPARTAMENTO INGENIERÍA DEL SOFTWARE E INTELIGENCIA ARTIFICIAL
LÍNEA DE INVESTIGACIÓN: VISIÓN POR COMPUTADOR



PROYECTO FIN DE MÁSTER
CURSO ACADÉMICO 2017-2018
CONVOCATORIA ORDINARIA DE JUNIO

SEGMENTACIÓN E IDENTIFICACIÓN DE TEXTURAS
EN IMÁGENES DE EXTERIOR

Autor: Joffre Luis León Veas

Director: Gonzalo Pajares Martinsanz

Autorización

El abajo firmante, matriculado en el Máster en Ingeniería de Sistemas y Control de la Facultad de Informática, autoriza a la Universidad Complutense de Madrid (UCM) y a la Universidad Nacional de Educación a Distancia (UNED) a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a su autor, tanto la memoria de este Trabajo Fin de Máster, como el código, la documentación y/o el prototipo desarrollado.

Firmado:

Joffre Luis León Veas

A mis hijos Andrés, Arianna, Arturo y Javier

Agradecimientos

A la Universidad Politécnica Salesiana porque plasmó en hechos las aspiraciones y metas que la engrandecen como Institución y a sus docentes como investigadores y profesionales.

A mi director del presente trabajo, el profesor Gonzalo Pajares Martinsanz, por su aceptación, su guía, su ayuda, sus observaciones para la realización de éste. También hago extensible este agradecimiento de igual manera a todos los profesores de las asignaturas del Máster.

Finalmente, agradezco a mis compañeros en el Programa del Máster, Teddy Negrete, Orlando Barcia, Olmedo Aguayo por haber enriquecido notablemente este trabajo.

Resumen

El presente trabajo se encuadra en el área de la Visión Artificial, en lo referente al tema de identificación y segmentación de objetos, específicamente de texturas presentes en espacios exteriores. El tema en concreto es la segmentación de texturas en imágenes correspondiente a campos agrícolas, especialmente campos de cultivos ubicados en la región Costa del Ecuador, zonas que están caracterizadas por ser intensivas en el cultivo de sembríos de banano, arroz, maíz, cacao, caña de azúcar, entre otros cuyo destino principal es la exportación.

De acuerdo con los resultados de la Revisión de 2017, la población mundial se situó en casi 7.600 millones a mediados de 2017, lo que implica que el mundo ha agregado aproximadamente mil millones de habitantes en los últimos doce años. (Proyecciones de población-UN, 2017)

Este gran crecimiento que la población humana experimentó durante los últimos dos siglos, sumado esto al desarrollo económico global, hace que la demanda por alimentos y otros bienes o servicios producidos por la agricultura mantenga un ritmo creciente de demanda.

Es un objetivo vital en este ámbito, la optimización de las labores que se llevan a cabo en los campos agrícolas, siendo esto el motivo por el que se plantea la necesidad de sistematizar estas tareas, en especial aquellas en las cuales sus procedimientos pueden permitir la utilización de máquinas herramientas robotizadas, cuyos sensores principalmente ópticos, tienen un papel muy importante.

Las imágenes que generan estos sensores deben ser procesadas lo mejor posible, por ejemplo uno de los aspectos más significativos es identificar las plantas, estructuras o patrones vegetales, contenidas en ellas, para luego separarlas de otros elementos que pueden también estar incluidos en la imagen, tales como el cielo, la tierra, agua, construcciones, entre otros.

El proyecto trata como se indica del problema de la identificación y clasificación de estructuras vegetales en imágenes de campos agrícolas, extraídos previamente aplicando técnicas de reconocimiento de patrones o aprendizaje automático, para su posterior tratamiento, en el contexto de los procesos de automatización, en lo que se conoce como "Agricultura de Precisión", donde destacan por ejemplo la aplicación inteligente de productos químicos, tales como herbicidas o fertilizantes, o la utilización de sistemas mecánicos para la eliminación de las maleza.

El objetivo principal del presente trabajo por tanto consiste en la implementación de diversas estrategias de identificación y clasificación de texturas, capaz de generar resultados aceptables sobre el tipo de imágenes proporcionado, luego de lo cual se procederá a realizar un análisis comparativo y en la medida de lo posible automatizar el proceso de detección y clasificación.

Se proponen por un lado los procedimientos bajo la perspectiva de los clasificadores clásicos en su versión original, a saber: el método de agrupamiento borroso, *K-means*, los mapas auto-organizativos y el método de cuantización vectorial, y por otro lado el procedimiento más actualizado del desplazamiento de la media (*mean-shift*).

Palabras clave

Reconocimiento de patrones, segmentación, textura, visión por computador, red neuronal, *Fuzzy Clustering*, Mapas auto organizados, método de Otsu, Clasificación no supervisada.

Abstract

The present work fits in the area of Computer Vision or Artificial Vision, regarding the subject of recognition or identification and segmentation of objects, specifically of textures present in outdoor spaces. The specific subject is the segmentation of textures in images corresponding to agricultural fields, especially fields of crops located in the Coast region of Ecuador, areas that are characterized by being intensive in the cultivation of fields of banana, rice, maize, cacao, sugarcane of sugar, among others whose main destination is the export.

According to the results of the 2017 Review, the world population stood at nearly 7.6 billion by mid-2017, implying that the world has added approximately one billion people in the last twelve years. (Population Projections-UN, 2017)

This great growth that the human population experienced during the last two centuries, added to the global economic development, makes the demand for food and other goods or services produced by agriculture maintain an increasing rhythm of demand.

It is a vital objective in this area, the optimization of the work carried out in the agricultural fields, which is why it is necessary to systematize these tasks, especially those in which their procedures can allow the use of robotic machine tools, whose mainly optical sensors play a very important role.

The images generated by these sensors must be processed as well as possible, for example one of the most significant aspects is to identify the plants, structures or plant patterns contained in them, and then separate those from other elements that may also be included in the image, such as sky, earth, water, buildings, among others.

The project deals with the problem of identifying and classifying plant structures in agricultural field images, previously extracted using patterns recognition techniques or automatic learning, for their subsequent processing, in the context of automation processes, in the Which is known as "Precision Agriculture", where for example the intelligent application of chemicals, such as herbicides or fertilizers, or the use of mechanical systems for the removal of weeds.

The main objective of the present work is therefore the implementation of different strategies of identification and classification of textures, capable of generating acceptable results on the type of images provided, after which a comparative analysis will be carried out and to the extent It is possible to automate the detection and classification process.

The procedures are proposed on the one hand from the perspective of classical classifiers in their original version, namely: the grouping method, the maximum likelihood parametric estimator, the non-parametric estimator of the Parzen window, the self-organizing maps and the vector quantization method, and on the other hand the most up-to-date procedure of the mean shift.

Keywords

Pattern Recognition, Segmentation, Texture, Computer Vision, Neural Network, Fuzzy Clustering, Self-Organized Maps, Otsu Method, Unsupervised Classification

Índice General

Contenido

Índice General	11
Índice de figuras	13
Índice de tablas	17
Siglas y Abreviaturas	19
1. Capítulo 1. Introducción.....	21
1.1. Motivación.....	21
1.2. Identificación del problema	23
1.3. Objetivos	24
1.4. Metodología	25
1.5. Organización de la memoria	25
2. Capítulo 2. Estado del arte.....	27
2.1 Antecedentes	27
2.2 Reconocimiento de patrones	28
2.3 Visión artificial.....	29
2.4 Métodos de segmentación por el análisis de la información espectral.....	30
2.4.1 Segmentación guiada por Umbralización	31
2.4.2 Segmentación guiada por Aprendizaje	31
2.4.3 Segmentación guiada por Índices cromáticos.....	33
2.5 Métodos de segmentación por el análisis de la información espacial.....	34
2.5.1 Segmentación guiada por Análisis de la ubicación espacial.....	34
2.5.2 Segmentación guiada por Análisis de la resolución espacial	35
2.6 Evaluación de las particiones mediante índices de calidad	36
3. Capítulo 3. Revisión de Métodos	39
3.1 Introducción	39
3.2 Principales algoritmos	40
3.2.1 <i>Fuzzy clustering</i> o Agrupamiento borroso	41
3.2.1.1. Algoritmo de Agrupamiento c-medias <i>fuzzy</i>	44
3.2.1.2. Índices de Validación de clústeres <i>fuzzy</i>	44
3.2.2 K-medias (<i>K-means</i>).....	46
3.2.3 Cuantización Vectorial.....	48
3.2.4 <i>Mean Shift</i> (Desplazamiento hacia la media).....	48
3.2.4.1 Introducción	48
3.2.4.2 Descripción del Algoritmo <i>Mean Shift</i>	49

3.2.5	Redes neuronales	53
3.2.5.1	El proceso de aprendizaje	53
3.2.5.1.1	Algoritmo de aprendizaje	54
3.2.5.1.2	Redes SOM	55
3.2.5.1.3	Arquitectura de las Redes SOM.....	56
3.2.5.1.4	Algoritmo de aprendizaje de las Redes SOM	57
3.2.5.1.5	Función de vecindad de las Redes SOM.....	58
3.2.5.1.6	Proceso de aprendizaje de las Redes SOM	59
3.2.6	Índices de Validación de clústeres <i>crisp</i>	60
3.2.6.1	Diámetro máximo del grupo (Δ).....	60
3.2.6.2	Separación de Clúster Mínima (δ).....	60
3.2.6.3	Índice de Calinski-Harabasz (CH).....	61
3.2.6.4	Índice de Dunn (D).....	61
3.2.6.5	Entropía (E).....	61
3.3	Método propuesto	62
3.3.1	Introducción	62
4.	Capítulo 4. Análisis de resultados	69
4.1	Introducción	69
4.2	Descripción de las bases de datos utilizadas.....	70
4.3	Elección de los índices de validación de clústeres	70
4.4	Base de imágenes para el estudio.....	71
4.5	Resultados obtenidos del método propuesto y estudio comparativo.....	71
4.5.1	Estudio detallado de casos.....	72
4.5.1.1	Muestra 1: 05020089.jpg	73
4.5.1.2	Muestra 2: 05020056.jpg	76
4.5.1.3	Muestra 3: 05020026.jpg	79
4.5.1.4	Muestra 4: 05020068.jpg	82
4.5.2	Comparación de Resultados.....	85
4.5.2.1	Indicadores de calidad de las agrupaciones.....	85
4.5.2.2	Tiempos de ejecución de los algoritmos	87
4.5.2.3	Errores de reconstrucción final	88
4.5.2.4	Ilustración de los resultados	91
5.	Capítulo 5. Conclusiones y trabajo futuro.....	97
6.	Referencias Bibliográficas	100
7.	Anexo	103

Índice de figuras

Figura 1. Texturas: Regular, estocástica, deformadas en el dominio espacial y en el rango.....	22
Figura 2. Texturas naturales de plantaciones de maíz y banano	23
Figura 3. Procesos de un Sistema de Clasificación	30
Figura 4. Esquema inicial del proceso de la investigación realizada	41
Figura 5. Algoritmo <i>K-means</i> , ejemplo de evolución de las iteraciones y determinación de los centroides finales, número de grupos igual a 3 y máximo de iteraciones igual a 10	46
Figura 6. Visión instantánea del Procedimiento de <i>Mean Shift</i>	51
Figura 7. Distintas topologías para las neuronas de salida en redes SOM.....	57
Figura 8. Esquema general del proceso de la investigación realizada	63
Figura 9. Esquema detallado de la Segmentación por la información de cromaticidad.....	66
Figura 10. Muestra 1: Imagen de estudio “05020089.jpg” en espacio RGB	74
Figura 11. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 1.....	74
Figura 12. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c) de la muestra 1.....	75
Figura 13. Imágenes segmentadas por índices de cromaticidad de la muestra 1, con las estructuras vegetales en (a) y el suelo en (b)	75
Figura 14. Imagen de la muestra 1, redimensionada al 10 por ciento de la imagen original en espacio RGB.....	76
Figura 15. Imagen de la muestra 1, reconstruida a partir de 18 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad	76
Figura 16. Muestra 2: Imagen de estudio “05020056.jpg” en espacio RGB	77
Figura 17. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 2.....	77
Figura 18. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a) y Exceso de Rojo (ExR) en (b) de la muestra 2	78
Figura 19. Imágenes segmentadas por índices de cromaticidad de la muestra 2, con las estructuras vegetales en (a) y el suelo en (b)	78
Figura 20. Imagen de la muestra 2, redimensionada al 10 por ciento de la imagen original en espacio RGB.....	79
Figura 21. Imagen de la muestra 2, reconstruida a partir de 15 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad	79
Figura 22. Muestra 3: Imagen de estudio “05020026.jpg” en espacio RGB	80
Figura 23. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 3.....	80
Figura 24. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a) y Exceso de Rojo (ExR) en (b) de la muestra 3	81
Figura 25. Imágenes segmentadas por índices de cromaticidad de la muestra 3, con las estructuras vegetales en (a) y el suelo en (b)	81

Figura 26. Imagen de la muestra 3, redimensionada al 10 por ciento de la imagen original en espacio RGB.....	82
Figura 27. Imagen de la muestra 3, reconstruida a partir de 17 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad	82
Figura 28. Muestra 4: Imagen de estudio “05020068.jpg” en espacio RGB	82
Figura 29. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 4.....	83
Figura 30. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c) de la muestra 4.....	83
Figura 31. Imágenes segmentadas por índices de cromaticidad de la muestra 4, con las estructuras vegetales en (a) y el suelo en (b)	84
Figura 32. Imagen de la muestra 4, redimensionada al 10 por ciento de la imagen original en espacio RGB.....	85
Figura 33. Imagen de la muestra 4, reconstruida a partir de 12 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad	85
Figura 34. Tiempo de ejecución para la extracción de características de los principales algoritmos	87
Figura 35. Principales estadísticas conjunto de entrenamiento: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del menor MSE alcanzado en los algoritmos ejecutados.....	88
Figura 36. Principales estadísticas conjunto de prueba: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del menor MSE alcanzado en los algoritmos ejecutados.....	89
Figura 37. Principales estadísticas conjunto de entrenamiento: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del voto mayoritario de CVI en los algoritmos ejecutados.....	89
Figura 38. Diagrama de cajas conjunto de entrenamiento: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del voto mayoritario del CVI en los algoritmos ejecutados.....	90
Figura 39. Principales estadísticas conjunto de pruebas: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del voto mayoritario del CVI en los algoritmos ejecutados.....	90
Figura 40. Principales estadística conjunto de pruebas: Error cuadrático medio (MSE) por algoritmo Descriptores obtenidos por el criterio del voto mayoritario del CVI en los algoritmos ejecutados.....	91
Figura 41. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por votos de los CVI de las agrupaciones.	92
Figura 42. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por el menor MSE de agrupación.....	92
Figura 43. Imagen codificada de acuerdo con los vectores de características detectados en tres ejecuciones del algoritmo propuesto, con la elección de centros por votos de los CVI de las agrupaciones.....	93

Figura 44. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por votos de los CVI de las agrupaciones.....	94
Figura 45. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por el menor MSE de agrupación.....	94
Figura 46. Imagen codificada de acuerdo con los vectores de características detectados en tres ejecuciones del algoritmo propuesto, con la elección de centros por votos de los CVI de las agrupaciones.....	95
Figura 47. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones.....	104
Figura 48. Muestra 4: Gráficas de los indicadores MSE y PSNR.....	104
Figura 49. Muestra 4: Gráfica reconstruida desde FC de la imagen a partir de los centros aprendidos	105
Figura 50. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por FC	105
Figura 51. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por FC.....	106
Figura 52. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones.....	107
Figura 53. Muestra 4: Gráficas de los indicadores MSE y PSNR.....	107
Figura 54. Muestra 4: Gráfica reconstruida desde <i>K-means</i> de la imagen a partir de los centros aprendidos	108
Figura 55. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por <i>K-means</i>	108
Figura 56. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por <i>K-means</i>	109
Figura 57. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones.....	110
Figura 58. Muestra 4: Gráficas de los indicadores MSE y PSNR.....	110
Figura 59. Muestra 4: Gráfica reconstruida desde LVQ de la imagen a partir de los centros aprendidos	111
Figura 60. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por LVQ	112
Figura 61. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por LVQ.....	112
Figura 62. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones.....	113
Figura 63. Muestra 4: Gráficas de los indicadores MSE y PSNR.....	113
Figura 64. Muestra 4: Gráfica reconstruida desde <i>Mean Shift</i> de la imagen a partir de los centros aprendidos	115
Figura 65. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por <i>Mean Shift</i>	115
Figura 66. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por <i>Mean Shift</i>	116
Figura 67. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones.....	117
Figura 68. Muestra 4: Gráficas de los indicadores MSE y PSNR.....	117
Figura 69. Muestra 4: Gráfica reconstruida desde SOM de la imagen a partir de los centros aprendidos	118
Figura 70. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por SOM.....	118

Figura 71. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por SOM.....	119
Figura 72. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones de vegetación .	120
Figura 73. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones de suelo	120
Figura 74. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones de cielo	121
Figura 75. Muestra 4: Gráfica reconstruida desde SOM + IC de la imagen a partir de los centros aprendidos	122
Figura 76. Muestra 4: Gráfica de las agrupaciones finales de los puntos de la imagen del espacio RGB, clasificados por SOM + IC	122
Figura 77. Muestra 4: Gráfica de las agrupaciones finales de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por SOM + IC	123

Índice de tablas

Tabla 1. Índice de validación de clúster, criterio a seguir para elección de la mejor partición ..	38
Tabla 2. Dataset desde el Repositorio UCI Repository y sus principales características	70
Tabla 3. Resumen estadístico de la ejecución de la investigación	71
Tabla 4. Resumen de los promedios de los indicadores MSE	72
Tabla 5. Agrupaciones sugeridas, reglas para cada CVI seleccionado	86
Tabla 6. Agrupaciones sugeridas, reglas para otros CVI	86
Tabla 7. Agrupaciones sugeridas, reglas del MSE y PNSR	86
Tabla 8. Resumen estadístico Tiempos promedios (segundos) por iteración y por algoritmo...	87
Tabla 9. Muestra 4: Centros aprendidos por el algoritmo FC	104
Tabla 10. Muestra 4: Centros aprendidos por el algoritmo <i>K-means</i>	107
Tabla 11. Muestra 4: Centros aprendidos por el algoritmo LVQ	111
Tabla 12. Muestra 4: Centros aprendidos por el algoritmo <i>Mean Shift</i>	113
Tabla 13. Muestra 4: Centros aprendidos por el algoritmo SOM	117
Tabla 14. Muestra 4: Centros aprendidos por el algoritmo SOM + IC	121

Siglas y Abreviaturas

CVI:	<i>Cluster Validation Index</i>
FC:	<i>Fuzzy Clustering</i>
JPG:	<i>Joint Photographic Experts Group</i>
KM:	<i>K-means</i>
LVQ:	<i>Learning Vector Quantization</i>
MS:	<i>Mean Shift</i>
MSE:	<i>Mean Square Error</i>
NIR:	<i>Near Infrared</i>
PCA:	<i>Principal Component Analysis</i>
PDF:	<i>Probability Distribution Function</i>
PSNR:	<i>Peak Signal-to-Noise Ratio</i>
RGB:	<i>Red, Green, Blue</i>
SOM:	<i>Self-Organizing Feature Maps</i>
UN:	<i>United Nations</i>

1. Capítulo 1. Introducción

1.1. Motivación

Vivimos el tiempo de la generación masiva de datos, por todo y para todo. Datos representando una variedad de escenarios, unos reflejando casos dentro del ámbito de lo tradicional, expresando características de sistemas tales como personas, empresas, gobiernos, industria, pero también otros datos reflejando otros ámbitos o fuentes que podríamos considerar como no convencionales o tradicionales, por ejemplo, para caracterizar sistemas como lo pueden ser los fenómenos climáticos, los sistemas biológicos o los sistemas sociales, entre otros.

Una vertiente que se ha transformado en una fuente enorme y permanente de información lo constituyen las imágenes digitales, las cuales pueden reflejar relaciones, algunas de las cuales son evidentes ante el sistema de visión humano, pero también pueden reflejar otras relaciones no tan claras, por estar involucrando escenarios diferentes, más complejos o menos obvios.

Toda esta información generada como imágenes digitales es posible por la disponibilidad de una gama muy variada de dispositivos, como son las cámaras digitales o los modernos teléfonos celulares, pasando por los dispositivos disponibles para reconocer el entorno y facilitar la navegación en una gran variedad de sistemas autónomos, así como los disponibles en los dispositivos para entornos industriales para el monitoreo de procesos o la realización de tareas específicas, hasta los sensores de satélites artificiales como elementos importantes de los equipos de teledetección.

Los datos generados por los dispositivos mencionados anteriormente se deben preparar o adecuar a las necesidades concretas de alguna aplicación y de conformidad con los requerimientos específicos de alguna temática de interés, que se puede organizar de manera general en las áreas de la agricultura, la oceanografía, la hidrografía, la meteorología, la industria e infraestructura o edificaciones construidas por el ser humano, entre otras.

Se genera entonces la necesidad de diseñar e implementar procedimientos y sistemas que hagan posible procesar esa enorme cantidad de datos de una manera apropiada, entendiendo como tal la obtención de datos significativos que equivalgan a resultados adecuados en un contexto determinado, para un propósito específico y en un tiempo razonable, de conformidad al ámbito de la aplicación, que faciliten algunas tomas de decisiones.

Dos de los procesos iniciales que se incluyen en este contexto son la detección de estructuras dentro de las imágenes, así como su correspondiente clasificación. Por ejemplo, de manera específica se puede tratar de la detección y la clasificación de texturas naturales, de campos de cultivos, cuyo objetivo principal consiste en realizar una partición de la imagen digital en varias regiones, de tal forma que cada región se pueda caracterizar por su regularidad con respecto a algún aspecto previamente establecido, permitiendo determinar el cultivo, las malas hierbas, o la naturaleza del suelo como húmico, arcilloso, arenoso, entre otros.

Las texturas visuales son regiones de las imágenes que exhiben alguna forma de regularidad espacial. Éstas incluyen las llamadas texturas "regulares" o "cuasi-regulares", ver la Figura 1, arriba a la izquierda; las texturas "estocásticas", arriba a la derecha, posiblemente deformada ya sea en el dominio, como se ve en la parte inferior izquierda, o en el rango, parte inferior derecha. (Georgiadis, 2015)



Figura 1. Texturas: Regular, estocástica, deformadas en el dominio espacial y en el rango

En el contexto de los campos de cultivo mencionados, con el propósito de identificar las texturas subyacentes, en el presente trabajo se construirán clasificadores clásicos entre los que se encuentran los relacionados a continuación (Pajares y Cruz, 2007):

- Agrupamiento borroso ("*Fuzzy Clustering*").
- ISODATA, K-medias (*K-means*)
- Cuantización vectorial ("*Learning Vector Quantization*")
- Mapas Auto-Organizados (*Self-Organizing Feature Maps*).

A los que se agregará un nuevo clasificador aparecido en los últimos años (Fukunaga, 1975; Cheng, 1995; Comaniciu, 2002):

- Desplazamiento de la media (*Mean Shift*)

Los clasificadores citados se describen con gran detalle en el capítulo tres del presente documento por ser la base del trabajo planteado.

Para el problema a manejar se propone estudiar desde algunas perspectivas la estructura inherente en imágenes digitales de campos de cultivos, como los que se muestran en la figura 2, en ésta se pueden apreciar algunos elementos regulares que están contenidas en ellas, es así que por un lado está la presencia en una gran parte de las imágenes de vegetación, correspondientes a los campos de cultivos y posiblemente otras clases de vegetación parásita, las llamadas malas hierbas, específicamente en la figura indicada se muestran cultivos de maíz en la parte superior y cultivos de banano en la parte inferior, ambos muy frecuentes en las zonas rurales del Ecuador, también se pueden observar regiones de suelo y de cielo.



Figura 2. Texturas naturales de plantaciones de maíz y banano

Finalmente, se debe indicar citando el trabajo de Guijarro (2009), “La clasificación de texturas naturales se perfila claramente como uno de los procedimientos susceptibles de mejora, esto es así porque en la mayoría de los casos, los métodos simples de clasificación no proporcionan los resultados esperados, particularmente en imágenes de exterior como las utilizadas en este trabajo, cuya base son las texturas naturales. De aquí, surge la necesidad de investigar nuevas alternativas en el ámbito de la clasificación, orientada hacia la identificación de las mencionadas texturas naturales”.

1.2. Identificación del problema

Los clasificadores referidos previamente han sido ampliamente utilizados, principalmente a través de implementaciones en las herramientas disponibles en el mercado especializado, pero también por la realización de una muy variada gama de experimentos descritos en la

literatura, constituyendo una de las configuraciones de prueba el tema de la clasificación de texturas naturales en imágenes de exterior, lo que ha motivado incluso la realización de concursos o desafíos que se llevan a cabo de forma anual, como se expone en el capítulo dos.

El problema original, consiste en buscar el mejor conjunto de características y luego el mejor clasificador, sin embargo, también se puede buscar el mejor conjunto de características y de clasificadores, para luego proceder a identificar el mejor proceso de combinación. Así las cosas, en el presente trabajo se tratan de determinar las mejores maneras posibles de combinar los datos y métodos de los clasificadores o lo que es lo mismo la mejor manera de utilizar toda la información posible.

El punto aquí es que se quiere hacer una presentación de las herramientas y metodologías que disponemos en la actualidad, de forma que se las tenga en mente antes de salir en procura de nuevos diseños complicados. En este aspecto, la combinación de clasificadores parece ser el paso natural hacia adelante, cuando una variedad importante de alternativas de modelos de clasificadores individuales ha sido acumulado. Se plantea la necesidad de revisar los problemas fundamentales que surgen de este desafío, previniendo de no realizar repeticiones sin fin, derivados de esquemas cada vez más complicados, que sean resultado de la combinación de teorías, perdiendo de vista el problema original.

1.3. Objetivos

A partir de las consideraciones citadas en los párrafos anteriores, se plantean los siguientes objetivos de trabajo:

1. Estudio bibliográfico de la literatura existente en el ámbito de la visión artificial, la clasificación de texturas en imágenes y temas relacionados.
2. Construir y probar las principales estrategias de clasificación de texturas en imágenes.
 - a. Identificar la estructura general de la imagen para determinar áreas o secciones de cielo, suelo, cultivos y otras áreas.
 - b. Aislar la estructura de vegetación existente, del resto de elementos no relevantes presentes en la imagen.
 - c. Dentro de las estructuras vegetales identificadas, discriminar las diversas clases de plantas existentes.
3. Analizar los resultados obtenido a partir de los diversos clasificadores.

1.4. Metodología

En el desarrollo de este trabajo se ha seguido las pautas delineadas en el marco del método científico. Primeramente, se ha realizado una búsqueda de información bibliográfica en todas las fuentes disponibles. Se ha estudiado los antecedentes metodológicos y se ha analizado y evaluado el estado de la ciencia en esta área. Las etapas seguidas han sido:

1. Definición del problema de investigación.
2. Planteamiento de los objetivos de la investigación.
3. Formulación de planteamientos verificables.
4. Obtención de datos experimentales.
5. Clasificación, análisis e interpretación de los datos.
6. Conclusiones generales y descripción de líneas futuras de investigación.

Para la realización de los experimentos requeridos se han creado los programas de clasificación basados en las técnicas antes mencionadas. Este proceso abarca desde la adquisición de datos para la creación de una base suficientemente amplia con la que experimentar hasta la obtención de resultados, pasando por su visualización.

1.5. Organización de la memoria

Luego de la introducción, el documento se organiza de forma que en el capítulo dos se presenta el estado del arte, en la temática relacionada con la identificación y clasificación de texturas en imágenes de exteriores.

En el capítulo tres se realiza la prueba de los algoritmos citados en el estado del arte de manera directa e individual, para la resolución del problema. Luego de esto, con la verificación de los resultados obtenidos, se expone un nuevo método para la identificación de las texturas a partir de la combinación del uso de índices cromáticos y mapas auto-organizados.

En el capítulo cuatro se presentan los resultados obtenidos mediante el método propuesto, que se comparan con los resultados obtenidos de las pruebas realizadas por la aplicación directa de los algoritmos a las imágenes de entrenamiento.

Finalmente, en el capítulo cinco se exponen las conclusiones del estudio y se detallan las líneas de trabajo futuro a realizar.

2. Capítulo 2. Estado del arte.

2.1 Antecedentes

La agricultura tradicional considera los campos agrícolas como sistemas homogéneos en donde la aplicación de insumos y la realización de los distintos procedimientos requeridos no toman en cuenta la variabilidad espacial y temporal del proceso y de los resultados en la producción, menos aún el análisis de las causas de esa variabilidad. (Manual de agricultura de precisión: IICA, 2014)

Por otra parte, la agricultura de precisión contempla la aplicación de tecnologías y principios para el manejo de la variabilidad espacial y temporal asociada a todos los aspectos de la producción agrícola con el propósito de mejorar la productividad del cultivo y la calidad ambiental. (Pierce y Nowak, 1999)

Con este enfoque, las ventajas que se plantea la agricultura de precisión sobre la tradicional son bastante claras y contundentes debido a la posibilidad de utilizar los insumos de una forma cada vez más efectiva con la aplicación de medidas adecuadas, de conformidad a la necesidad efectiva de los cultivos. Esta propuesta de manejo de la agricultura permite la aplicación de insumos como químicos, sólo en las áreas en las que resulta necesario, donde la respuesta de esta intervención tendrá un claro impacto económico-ambiental, propiciando de forma clara la sostenibilidad en un espectro más amplio de la producción. Actualmente, dos herramientas útiles que posibilitan la aplicación de la agricultura de precisión son los sistemas de navegación global por satélites y los sistemas de información geográfica. (Pierce y Nowak, 1999)

Otra valiosa fuente de datos está representada por la adquisición remota de datos o teledetección, que es un conjunto de técnicas para obtener información sobre un objeto, área o fenómeno de la superficie terrestre, sin estar en contacto directo con ellos. A través de la detección, el registro y el análisis del flujo de energía radiante reflejado o emitido por estos cuerpos, las técnicas de teledetección permiten la diferenciación de algunas propiedades de los objetivos naturales, posibilitando así la identificación de características de componentes ambientales como las propiedades del suelo, morfología del terreno, patrones de cobertura vegetal, uso del suelo, entre otros. A través de los satélites se produce una adquisición continua de datos, cubriendo una misma área con una frecuencia temporal determinada, que varían de horas a semanas. En este ámbito, las fotografías aéreas, imágenes satelitales e imágenes de radar son productos obtenidos a través de la adquisición remota mediante sensores. (MAPA, 2013)

Finalmente, otra fuente de datos lo constituyen las imágenes obtenidas desde sensores de visión artificial, conocidos generalmente como cámaras, montados a bordo en maquinarias como tractores que son de uso común en los campos de cultivos o en otros casos como sistemas o *robots* terrestres utilizados sobre los terrenos de cultivos, que permiten la realización más eficiente de algunas de las actividades propias de la producción agrícola, como lo son el riego, la aplicación de nutrientes, la eliminación de malas hierbas o la aplicación de diversos químicos fitosanitarios para control de plagas incluso, siendo éstas imágenes el objeto de nuestro estudio.

Gran parte de ellos han sido diseñados para detectar las plantas verdes mediante diferentes sistemas sensoriales basados en visión artificial en función de sus respuestas espectrales a las distintas longitudes de ondas, por ejemplo, los que adquieren las imágenes en el espectro visible en forma de imágenes RGB o los que captan el infrarrojo cercano, NIR. (Gée y col, 2008)

2.2 Reconocimiento de patrones

El reconocimiento de patrones es la disciplina científica cuyo objetivo es la clasificación de objetos en una serie de categorías o clases. Dependiendo de la aplicación, estos objetos pueden ser el contenido de las imágenes, formas de onda de alguna señal o cualquier tipo de medidas que necesitan ser identificadas. Nos referiremos a estos objetos usando el término genérico de patrones. Como con todo lo demás, el advenimiento de las computadoras aumentó la demanda de aplicaciones prácticas del reconocimiento de patrones, lo que a su vez estableció nuevas demandas para desarrollos teóricos adicionales. A medida que nuestra sociedad evoluciona de la fase industrial a su fase postindustrial, la automatización en la producción industrial y la necesidad de manejo y recuperación de información son cada vez más importantes, particularmente si nos introducimos en el nuevo paradigma de lo que se conoce como industria 4.0. Esta tendencia ha impulsado el reconocimiento de patrones a la vanguardia de las aplicaciones de ingeniería actuales y la investigación. El reconocimiento de patrones es una parte integral de la mayoría de los sistemas de inteligencia de máquina construidos para la toma de decisiones. (Theodoridis, Koutroumbas, 2009)

Actualmente, la tecnología nos permite capturar, procesar y almacenar gran cantidad de datos que describen aspectos claves de los sistemas físicos que utilizamos, de igual manera, los investigadores están desarrollando nuevos modelos y mejorados algoritmos para trabajar con estos datos, propiciando la evolución de los sistemas conceptuales. Todo ello, en un entorno

de economía global que ha desatado el creciente interés comercial e industrial por obtener datos, información y finalmente conocimiento, que permita la automatización de tareas que requieren inteligencia en mayor o menor grado, facilitando así el desarrollo de sistemas inteligentes.

Algunas de estas tareas, como el reconocimiento de objetos, no requiere de mayor esfuerzo para un ser humano. Este proceso lo realizamos a diario, reconociendo objetos, independientemente de que pueda haber diversos factores que pueden dificultar la tarea, como la variación en la iluminación sobre el objeto, la postura y oclusiones sobre éste y hasta factores que afecten su estructura o integridad.

Resulta plenamente comprensible que debamos buscar, diseñar y construir máquinas que puedan reconocer patrones. Desde el reconocimiento automático de voz, la identificación de huellas dactilares, el reconocimiento óptico de caracteres, identificación de secuencias de ADN y mucho más, está claro que el reconocimiento de patrones confiable y preciso por máquina sería inmensamente útil. Además, al resolver los problemas innumerables requeridos para construir estos sistemas, adquirimos una comprensión y apreciación más profunda de los sistemas de reconocimiento de patrones en el mundo natural, especialmente en los seres humanos. Para algunas aplicaciones, como el reconocimiento de voz y visual, nuestros esfuerzos de diseño pueden de hecho ser influenciados por el conocimiento de cómo se resuelven en la naturaleza, tanto en los algoritmos que empleamos como en el diseño de un *hardware* de propósito especial. (Duda y col., 2001)

2.3 Visión artificial

La Visión Artificial se la describe como la capacidad de una máquina para ver el mundo que le rodea, deduciendo la estructura y las propiedades del mundo tridimensional a partir de una o más imágenes bidimensionales. (Pajares y Cruz, 2007)

La visión artificial o visión por computador es un área en la que el reconocimiento de patrones es una actividad importante. Un sistema de visión por computador captura imágenes a través de un sensor y las analiza para producir descripciones de lo que está en la imagen. Una aplicación típica de un sistema de visión por computador está en la industria de fabricación, ya sea para la inspección visual automatizada o para la automatización de una línea de montaje. (Duda y col., 2001)

El proceso se resume en el diagrama mostrado en la Figura 3:

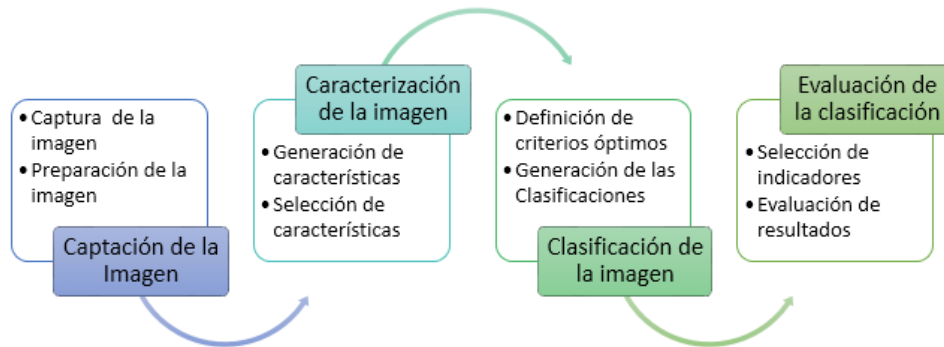


Figura 3. Procesos de un Sistema de Clasificación

Dentro del esquema de la Figura 3, el módulo correspondiente a la captación de imágenes depende del dispositivo de captura utilizado (sensor) y la plataforma que lo soporta, tanto como de la ejecución del tratamiento previo de la imagen con el fin de prepararla para la siguiente fase. La caracterización de la imagen es la fase que consiste en la segmentación o generación de estructuras que describirán los elementos contenidos en la imagen y que termina con la selección de los descriptores más adecuados para la siguiente fase de clasificación, que constituye la fase dentro del proceso donde se lleva a cabo la asignación requerida, tarea que se cumple previamente al aseguramiento de resultados mínimos aceptables lo que queda determinado en la última fase correspondiente a la evaluación de la clasificación. Opcionalmente, si los resultados no se ajustan a mínimos aceptables de conformidad a los requerimientos se puede optar por actualizar la base de características, para incluir las nuevas características no bien correlacionada en el proceso de clasificación con la base disponible, asegurando así mejores resultados para próximas ejecuciones del sistema.

2.4 Métodos de segmentación por el análisis de la información espectral

La segmentación de imágenes es un proceso mediante el cual a partir de la identificación y descripción de algunas características locales trata de identificar en una imagen partes que la componen, las cuales, a su vez de acuerdo con los objetivos establecidos se los define como objetos de interés y el fondo.

El objetivo de la segmentación en el análisis espectral es buscar representaciones de los elementos contenidos en la imagen en función del hallazgo de combinaciones específicas de valores de las señales componentes del color de los distintos elementos presentes, luego con estos datos es posible simplificar la representación de la imagen de forma que ésta sea reproducida o descrita, con un cierto grado de calidad o precisión a partir de los valores encontrados, resultando posiblemente más fácil de estudiar.

Las imágenes de interés en este estudio están constituidas por regiones o zonas que tienen unas características regulares. Esta regularidad puede ser vista desde el punto de vista del color o lo que es lo mismo, por la respuesta con respecto a determinadas señales del espectro electromagnético, por ejemplo, señales en el rango del espectro visible. Alternativamente, la regularidad puede ser establecida en una única señal que caracteriza los elementos en ausencia de color, como imágenes constituidas por objetos apreciados en escala de grises. En ambos escenarios la tarea es identificar, describir y sintetizar descriptores de las imágenes de base (entrenamiento) que puedan ser utilizados luego para el análisis de otras imágenes (prueba) con similares características.

2.4.1 Segmentación guiada por Umbralización

La umbralización es el método más simple definido para la segmentación de una imagen digital. A partir de una imagen en escala de grises se puede utilizar la umbralización para crear imágenes binarias (Shapiro y Stockman, 2001), el umbral es un valor a partir del cual se puede decidir si un píxel es considerado como perteneciente a una clase o no. Un umbral sencillo de implementar es el basado en el valor medio del nivel de gris de la imagen, calculado a partir del histograma, que se ha propuesto en los estudios de (Gée y col., 2008), tras su aplicación, la parte vegetal de cultivo y maleza aparece en una imagen resultado como secciones de color blanco y el resto de los elementos se apreciarán de color negro.

Cabe indicar, dentro de los métodos de umbralización, que el método de Otsu (Otsu, 1979) es uno de los más utilizados, puesto que genera una muy buena respuesta frente a la mayoría de las situaciones de aplicación del mundo real, no necesitando además supervisión, perteneciendo así a los procedimientos de segmentación de imágenes de naturaleza biclase (Shrestha y col, 2004). Según se establece en Sesgin y Sankur (2004) el método de Otsu obtiene resultados satisfactorios cuando el número de píxeles en cada lóbulo del histograma es similar, no trabajando bien en otras imágenes, ya que tiende a la infra segmentación, siendo en estos casos mejor utilizar la media estadística.

2.4.2 Segmentación guiada por Aprendizaje

En una imagen digital como objeto que recoge una parte de la realidad que nos rodea, muestra las estructuras presentes, evidencia de las diferentes clases de elementos que contiene. Estos elementos establecen la existencia de patrones que son percibidos debido a la organización de algunos de sus atributos como su composición, el color y la forma, dando lugar a texturas

visuales, que determinan la distinta naturaleza de los elementos que la imagen digital contiene.

Este escenario constituye un dominio de aplicación importante para el desarrollo de diversas técnicas de análisis y aprendizaje que ayuden a la formulación de modelos que puedan ser utilizados para la comprensión y el estudio de este tipo de sistemas.

Es así como surge el término Aprendizaje Máquina, ligado inicialmente a la Inteligencia Artificial, campo en el que se desarrollaron gran número de técnicas como las redes neuronales donde destacan las de Kohonen denominadas de auto-organización y auto-aprendizaje, o bien el método de aprendizaje de árboles binarios y los trabajos iniciales en el perceptrón que condujeron posteriormente a las redes neuronales del tipo retropropagación. De manera simultánea se han ido produciendo grandes avances en el aprendizaje en el campo de la estadística, dando lugar al aprendizaje estadístico, en este ámbito se tiene algunas técnicas por ejemplo el clasificador paramétrico de Bayes, el clasificador no paramétrico de la ventana de Parzen y el agrupamiento borroso. (Omatu, 2015; Pajares y Cruz, 2011)

Además, entre los métodos de aprendizaje estadístico, las máquinas de vectores soporte (SVM) es otro de los métodos más comúnmente utilizado en la investigación de problemas de clasificación de patrones. (Yingjie, 2014)

Finalmente, estudiaremos el algoritmo de *Mean Shift* o de desplazamiento hacia la media, definido ampliamente en la literatura (Comaniciu y Meer, 2002; Cheng, 1995; Fukunaga, 1975). Es una técnica no paramétrica general para el análisis de un espacio de características multimodal complejo y para delinear en él clústeres de forma arbitraria, (Comaniciu y Meer, 2002). Surge de la combinación del uso de la estrategia no paramétrica de la ventana de Parzen para la estimación de la función de densidad y la posterior estimación de sus modas, de forma que, las modas calculadas serán la referencia de los centros de los clústeres contenidos en la imagen.

Finalmente, y aunque no constituyen el objeto del presente trabajo cabe destacar las denominadas redes neuronales convolucionales (*Convolutional Neural Networks, CNN*) situadas en el ámbito del aprendizaje profundo (*deep-learning*) con excelentes perspectivas de futuro (Bianco y col., 2017; Dumoulin and Visin, 2018).

2.4.3 Segmentación guiada por Índices cromáticos

Los índices cromáticos en general se obtienen mediante la definición de alguna combinación lineal de los valores de intensidad de los planos de color RGB, siendo modificados por constantes que se han determinado por experimentación. Los índices cromáticos o de color de vegetación utilizan solamente las bandas espectrales rojas, verdes y azules. La ventaja de usar los índices de color es que acentúan un color particular tal como el verde de la planta, que debe ser intuitivo por la comparación humana. (Meyer, 2011)

En particular, los índices de vegetación son medidas empíricas obtenidas al cuantificar y combinar dos o más bandas del espectro electromagnético, normalmente el espectro visible y el infrarrojo cercano, que reflejan la vegetación de una manera característica. Con los índices de vegetación se trata de obtener datos con los que caracterizar la vegetación en el escenario que se quiere analizar facilitando su separabilidad de otros elementos presentes en la imagen. Dentro de estos índices es posible hacer una diferenciación, por un lado, están los que emplean el espectro infrarrojo cercano (NIR) y por otro los que hacen uso únicamente las bandas del espectro visible.

Se requiere un índice de vegetación que sea preciso para identificar la biomasa de las plantas frente a los fondos de suelos y otros elementos para las aplicaciones de visión artificial o por computadora, las evaluaciones de las plantas, el manejo preciso de los cultivos y el control de las malas hierbas (Meyer, 2011). De igual manera es requerido un conjunto de índices que ayuden a la detección del suelo y del cielo en las imágenes puesto que por tratarse de áreas abiertas de cultivo las imágenes probablemente incluyan porciones de estos elementos.

Un índice utilizado en muchos trabajos existentes en la literatura, con buenos resultados, es el exceso de verde ExG, (Woebbecke y col., 1995) que sirve para la discriminación de plantas bien como índice base o bien para su comparación con otros índices, (Meyer y col. 1998; Ribeiro y col. 2005; Tellaache y col., 2008; Meyer y Camargo Neto, 2008) informaron sobre el desarrollo de un Índice cromático de vegetación mejorado: Exceso de Verde menos Exceso de Rojo, ExG-ExR. Este índice no requiere de un umbral y se compara favorablemente con el índice Exceso de Verde (ExG) comúnmente usado; (Peña y Torres-Sánchez, 2014) para discriminar entre vegetación y suelo desnudo, en la detección de malas hierbas en cultivos de girasol de fase temprana mediante imágenes tomadas con un vehículo aéreo no tripulado (UAV) utilizaron el índice ExG, obteniendo resultados satisfactorios a pesar de que las imágenes fueron tomadas volando a distintas alturas.

Los índices revisados transforman la imagen de color a escala de grises, puesto que definen una única banda de respuesta, por lo que se hace necesario encontrar un umbral a partir del cual poder decidir si un píxel es considerado como planta, suelo, cielo o cualquier otro elemento, de esta forma podemos conseguir, por ejemplo, una imagen binaria donde los píxeles que identifican la vegetación se etiquetarán con blancos y el resto con negro. En general, estas técnicas suponen la solución de un problema de segmentación de dos clases. Los enfoques basados en umbrales, se puede extender con lo que se conoce como umbralización dinámica, que considera múltiples regiones de vecindad en lugar de una sola esto es, la imagen completa.

2.5 Métodos de segmentación por el análisis de la información espacial

La información contenida en las imágenes digitales ciertamente no incluye solamente datos de naturaleza espectral, por lo que el proceso de identificación y segmentación en las estructuras contenidas en la imagen puede incluir otros elementos relevantes para su realización, como por ejemplo el uso de la información de localización espacial de los elementos, es por este motivo que en esta sección presentaremos de manera general algunas de las técnicas disponibles.

Cabe indicar además, que esta información a su vez puede ser vista desde dos perspectivas para su análisis. La primera haciendo notar que algunos de los elementos se ubican dentro de la imagen de acuerdo a algún patrón de ubicación, por ejemplo píxeles siguiendo una línea o conformando una serie de superficies de carácter regular o irregular, pero también como segunda perspectiva, esta información puede encerrar datos de elementos similares pero que se encuentren ubicados a distintas distancias con respecto a algún punto, lo que deriva en el concepto de escala de los elementos y que aquí será tratado brevemente.

Con el fin de mejorar la precisión de la clasificación de los objetos en las imágenes con información espacial, se han propuesto algunos métodos de clasificación espectral-espacial, como *Mean Shift* (Comaniciu y Meer, 2002) y la utilización de la transformación de *Wavelets*, (Guijarro, y col., 2015). Estos métodos de clasificación espectral-espacial utilizan diferentes estrategias para incorporar la información espacial.

2.5.1 Segmentación guiada por Análisis de la ubicación espacial

Los métodos expuestos en la sección 2.4, sólo hacen uso de la información espectral, sin utilizar la importante información espacial evidentemente contenida en las imágenes. Existe

un gran número de regiones homogéneas y las muestras ubicadas en la misma región homogénea son más proclives a que formen parte de una misma clase de objeto. Así, la información espacial disponible se puede utilizar para mejorar la precisión de clasificación de los elementos contenidos en la imagen.

Una imagen es representada en el dominio espectral como una matriz de puntos o píxeles de dimensión r , donde r es uno en el caso de imágenes en escala de grises, r es igual a tres en imágenes a color y r es mayor que tres en el caso de imágenes multispectrales o hiperespectrales, cabe indicar que los valores contenidos en cada celda de la matriz corresponden a los valores de respuesta a alguna señal, parte del espectro electromagnético, por ejemplo la intensidad, por esta razón el espacio de características es definido en el dominio del rango, para las imágenes RGB siendo igual a tres, \mathbf{R}^3 . Por otro lado, la localización de los píxeles está determinada en el dominio espacial, en el caso de las imágenes digitales, fundamentalmente el espacio bidimensional \mathbf{R}^2 . Ambos dominios pueden conformar un nuevo dominio, el llamado dominio extendido de dimensión d igual a cinco, \mathbf{R}^5 . Para ambos dominios se puede suponer el uso de una misma métrica de distancia, por ejemplo la euclidiana. Esta es la estrategia que se maneja en la propuesta del algoritmo de *Mean Shift*. (Comaniciu y Meer, 2002)

2.5.2 Segmentación guiada por Análisis de la resolución espacial

Las *wavelets* constituyen otra potente herramienta para afrontar problemas significativos en el tratamiento de imágenes, donde destacan temas relacionados con el énfasis en altas frecuencias o suavizado en las bajas. Esta teoría ha experimentado un gran desarrollo en las dos últimas décadas mostrándose muy eficiente en donde otras técnicas no derivan en resultados satisfactorios, siempre en el marco de los dominios transformados. (Riomoros, 2016)

La transformada *wavelets* divide la imagen original en imágenes de menor resolución espacial, obteniendo una que viene a ser una copia de la imagen original a menor resolución y que se suaviza mediante operaciones de filtrado paso bajo, además se obtiene otras tres imágenes más que contienen información relativa a los cambios locales en la imagen original y por tanto a las altas frecuencias, generadas mediante operaciones de filtrado paso alto. El primer resultado se conoce como coeficientes de aproximación, mientras que los otros tres son los denominados coeficientes de detalle, específicamente coeficientes verticales, horizontales y diagonales. El procedimiento base consiste en aplicar filtros de tipo paso bajo y alto, convenientemente combinados, cuyos coeficientes se obtienen a partir de lo que se conoce

como familias de *wavelets* incluyendo *Haar*, *Daubechies*, *Coiflets* entre otras muchas. La descomposición de la imagen en los mencionados componentes constituye uno de los asuntos clave para su aplicación en la combinación de información en las imágenes. Algo que forma parte del proceso seguido en (Guijarro y col., 2015), para mejorar la segmentación de las imágenes de campos de cultivo a través de las texturas de las partes vegetales, pero que no se desarrollará en el presente trabajo.

2.6 Evaluación de las particiones mediante índices de calidad

Los diferentes enfoques para lograr el agrupamiento, las diferentes configuraciones y la selección del número de clúster, cuando es un dato necesario, conducen a diferentes soluciones para el mismo conjunto de datos (Duda y col., 2012). Por este motivo, la evaluación para determinar si la partición es correcta o mejor que alguna otra se convierte en una tarea decisiva para procesos posteriores como puede ser la clasificación de los objetos. Para este propósito los índices de calidad o índices de validación de clúster (CVI) son utilizados para medir la bondad de las particiones obtenidas por los algoritmos de clasificación. Según Theodoridis y col. (2009) existen tres criterios con tal propósito: internos, externos y relativos.

Tanto los criterios internos como externos están basados en métodos estadísticos. Los índices internos son usados para medir la bondad de la clasificación sin información externa, evalúan los resultados generados únicamente usando cantidades y rasgos propios del conjunto de datos de entrada. Por este motivo, estos índices son los que se utilizarán en el presente estudio con el propósito de alcanzar la automatización de los métodos de clasificación.

Existe un gran número de índices de validación de clúster que se pueden encontrar en la literatura, sin embargo, no hay muchas directrices para decidir cuál es el índice más adecuado para un determinado conjunto de datos (Brun, Sima y col, 2007; Maulik, 2012). No obstante, parece claro que cada uno puede dar información relevante sobre alguna propiedad estructural distinta de la partición como puede ser la homogeneidad, la compacidad, la variabilidad, la separación de los clústeres, entre otras, que son independientes del contexto por lo que la evaluación basada en éstos se hace principalmente en términos de la topología de los clústeres. (Sevilla y col., 2016)

La mayoría de los trabajos realizados en la validación de clústeres en el contexto no supervisado se centran en la validación interna de los clústeres (Arbelaitz y col., 2013; Bezdek, 1998), es decir a partir de la generación de un indicador obtenido de los mismos datos de

muestra. Sin embargo, trabajos previos han demostrado que no hay un único CVI superando al resto (Brun y col, 2007; Maulik, 2012).

No obstante de lo antes expresado, para este estudio se acoge la propuesta establecida en (Sevilla y col., 2016) para la evaluación de los resultados obtenidos en los distintos algoritmos utilizados, excepto en los agrupamientos borrosos, en el que se utilizará una batería de indicadores de evaluación de calidad específicos para agrupamientos difusos, definidos en Pajares y Cruz (2011).

En Sevilla y col. (2016) se establece que la topología de las clases contenidas en una colección de datos puede ser entendida mediante el cálculo del siguiente conjunto de índices de calidad: Diámetro (Δ), Separación (δ), Calinski-Harabasz (CH), Dunn (D) y Entropía (E).

En realidad en ese estudio se establece una notación común para la formulación de los indicadores de validación de grupos, donde se puede observar mediante un Análisis de Componentes Principales (PCA, *Principal Component Analysis*) que los índices estudiados evalúan un conjunto determinado de características de una partición y según su definición, estos índices pueden agruparse alrededor de cuatro conceptos básicos:

- Índices que miden la compacidad de los conglomerados: Diámetro (Δ), Brecha máxima (WG), Distancia media dentro del grupo (W) y Suma de cuadrados dentro de los grupos (WSS);
- Índices que miden la separación entre grupos: Distancia promedio entre clústeres (B), Separación de clúster mínima (δ), Índice de separación (*Sindex*);
- Índices que miden las relaciones entre compacidad y separación: Dunn, Dunn-like, Calinski-Harabasz (CH), Coeficiente Gamma Hubert Normalizado (Γ), Siluetas, el Índice de Baker y Hubert (BH), Índice de Relación de distancias Dentro-Entre (WBR), C-Index y índice de Davies-Bouldin;
- Índices que miden el caos en los conglomerados: Entropía.

En teoría, cada índice es intercambiable para cualquier índice del mismo grupo, componente o atributo de la partición, ya que miden las mismas características (Sevilla y col., 2016).

Un resumen de las acciones a seguir por cada indicador, dependiendo del tipo de partición, se muestra en la tabla a continuación:

Tabla 1. Índice de validación de clúster, criterio a seguir para elección de la mejor partición

Estrategia	Indicador	Criterio
<i>Fuzzy</i>	Coeficiente de partición (CP)	máximo
	Índice de partición (SC)	mínimo
	Índice de Separación (S)	mínimo
	Índice de Dunn (DI)	máximo
	Coeficiente de entropía (CE)	mínimo
	Coeficiente de Xie Beni (XB)	mínimo
	<i>Crisp</i>	Diámetro máximo del grupo (Δ)
Separación de Clúster Mínima (δ)		máximo
Índice de Calinski-Harabasz (CH)		máximo
Índice de Dunn (DI)		máximo
Índice de entropía (E)		mínimo
Coeficiente de Xie Beni (XB)		mínimo
Distancia media dentro del grupo (W)		mínimo
Suma de cuadrados dentro de los grupos (WSS)		mínimo
Índice de Davies-Bouldin (DB)		mínimo

3. Capítulo 3. Revisión de Métodos

3.1 Introducción

Comenzamos la revisión de métodos presentando de forma cronológica las estrategias seguidas para la solución del problema de investigación, para seguidamente esquematizar la estructura general del programa que se ha desarrollado para evaluar los distintos algoritmos, junto con el detalle de las actividades desarrolladas en cada uno de ellos.

Se inicia el trabajo de investigación con el objetivo establecido para reconocer de forma automática en un campo de cultivo el número de clases presente, esto nos lleva a determinar elementos descriptores de la parte verde, que incluye el cultivo y las malas hierbas, que nos permita diferenciarlos del resto del contenido de la imagen, cielo, suelo y quizás algunos otros objetos sin interés para la investigación, tales como ríos, puentes, carros, torres eléctricas, entre otros. La tarea se puede ver complicada por las cambiantes condiciones de iluminación en los entornos de exterior de donde se tienen las imágenes digitales.

La investigación se realiza en dos partes, a saber:

- Primera parte, ejecución iterativa de los principales algoritmos para la segmentación y clasificación de imágenes, aplicados de manera directa en el conjunto de entrenamiento y realizando la modificación sistemática de los valores dados a sus parámetros, comenzando desde un valor inicial, hasta un valor final y/o hasta llegar a un cierto número de iteraciones. Luego de lo cual se procede a la selección del mejor grupo de características obtenidas a partir del cálculo del menor error de reconstrucción de la imagen, medido esto a través del cálculo del error cuadrático medio (MSE, *Mean Square Error*) (Wackerly D. y Scheaffer W. 2008) entre la imagen original y las imágenes reconstruidas o recodificadas a partir de las características obtenidas por el algoritmo, para las distintas agrupaciones generadas, seleccionando la que produzca el menor error; alternativamente se puede también escoger como elemento de decisión para el número de agrupaciones presentes, la relación de señal – ruido pico (PSNR, *Peak Signal-to-Noise Ratio*) entre la imagen original y las imágenes reconstruidas y seleccionando la que produzca la mayor relación.
- Segunda parte, en esta parte de la investigación, se realiza la segmentación gruesa de la imagen para separar la estructura vegetal, del cielo y el suelo, de acuerdo con el contenido de la imagen, por medio de la aplicación de umbralización de los

rastros de estos componentes de la imagen original, que a su vez son obtenidos por la aplicación de índices cromáticos, para luego proceder a realizar un análisis más exhaustivo de las estructuras (imágenes) separadas y la validación de los resultados obtenidos, mediante la generación y evaluación de los índices de validación de clústeres correspondientes y decidiendo la mejor agrupación por decisión de voto mayoritario de los criterios definidos para cada indicador.

Una vez descritas las texturas de las imágenes mediante los vectores de características seleccionados en cualquiera de los casos de los procesos anteriores, se está listo para realizar la siguiente tarea prevista en el objetivo de investigación, esto es clasificar una nueva imagen.

En este proceso cada uno de los píxeles de la imagen se asocia asociado al grupo que le corresponda de acuerdo con las diferentes texturas detectadas en la imagen y de conformidad a la base de aprendizaje de las características obtenida en la fase de entrenamiento. La imagen de prueba se procesa mediante el algoritmo de *K-means*, que es usado como método de clasificación de referencia, en conjunto con la base de características para realizar la clasificación final de los píxeles.

3.2 Principales algoritmos

En esta primera parte se realiza la ejecución iterativa de los principales algoritmos para la segmentación y clasificación de imágenes, aplicados de manera directa en el conjunto de datos de entrenamiento, con la modificación sistemática de los valores dados a sus parámetros.

Se comienza desde un valor inicial, hasta un valor final y/o hasta llegar a un cierto número de iteraciones. Luego de lo cual se procede a realizar la selección del mejor grupo de características obtenidas en las iteraciones a partir del cálculo del menor error de reconstrucción de la imagen, dato que es medido a través del cálculo del error cuadrático medio entre la imagen original y las imágenes reconstruidas a partir de las características obtenidas por el algoritmo correspondiente, para las distintas agrupaciones generadas, seleccionando lógicamente la que produzca el menor error. Alternativamente, se puede también proceder mediante la elección de la agrupación que ofrezca los mejores indicadores de validación de clústeres. Por último la labor final de clasificación de una nueva imagen se realiza luego de construida la base, para cada uno de los algoritmos mencionados, mediante el uso del algoritmo de *K-means*.

El proceso general se muestra en la figura 4, siendo aplicada esta estructura para la experimentación con los algoritmos, *fuzzy clustering* (FC), *K-means* (KM), aprendizaje por cuantización vectorial (LVQ), desplazamiento hacia la media (MS) y redes neuronales de mapas auto-organizados (SOM).

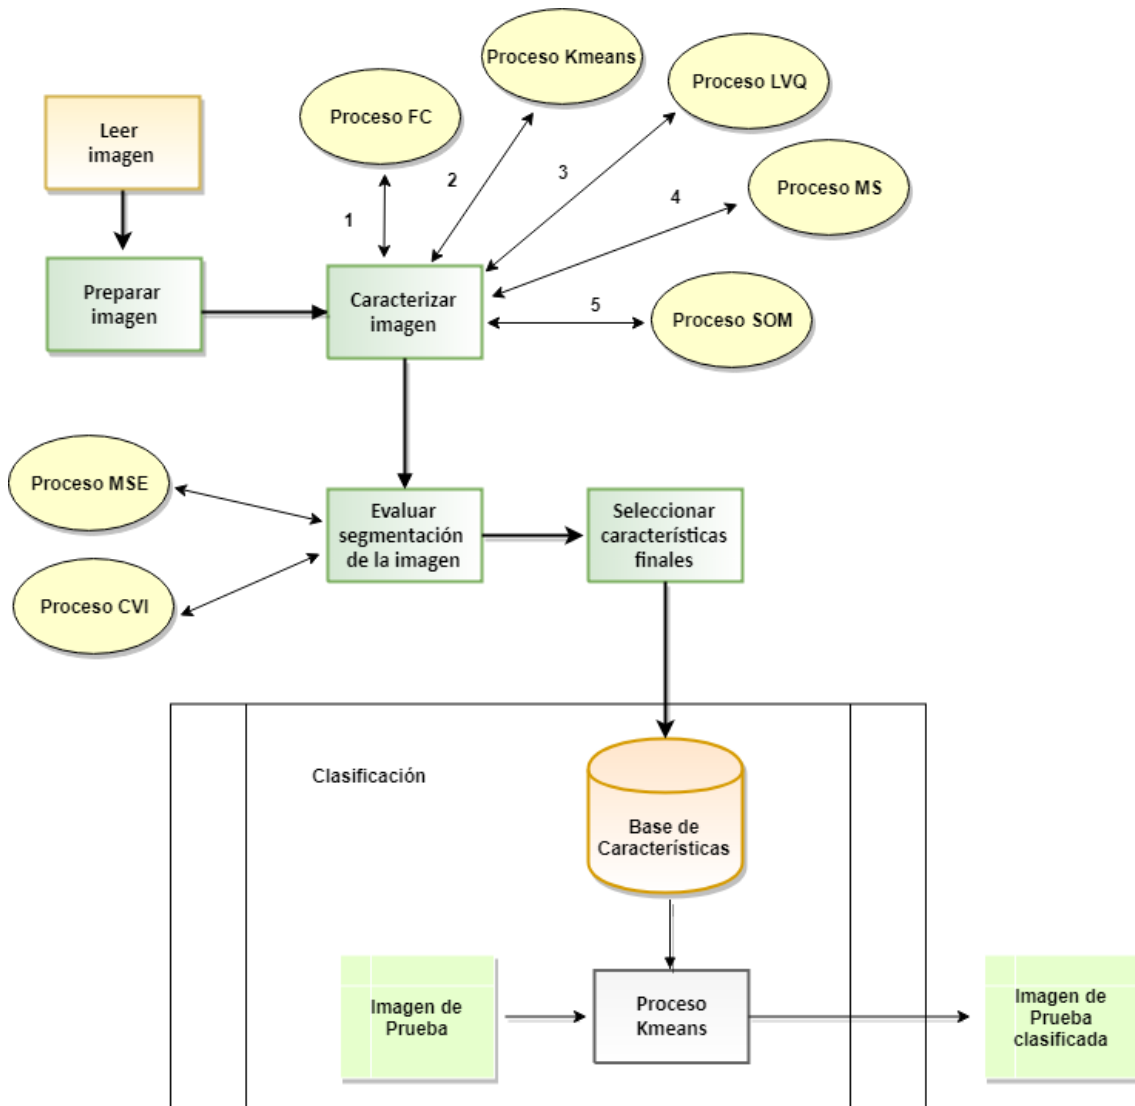


Figura 4. Esquema inicial del proceso de la investigación realizada

3.2.1 Fuzzy clustering o Agrupamiento borroso

El objetivo del método de agrupamiento borroso consiste en dividir n objetos $x \in X$ que son caracterizados por p propiedades en c clústeres o agrupaciones. Supongamos el conjunto de datos definidos por $X = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}^p$ un subconjunto de datos del espacio real p -dimensional \mathbf{R}^p . Cada $x_k = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}^p$ se denomina vector de características, donde x_{kj} es la j -ésima característica de la observación x_k . (Pajares y Cruz, 2007)

Puesto que los elementos de un clúster deben ser tan similares entre sí como sea posible y a la vez deben ser tan diferentes a los elementos de otros clústeres como también sea posible, el proceso se controla con el uso de medidas de similitud basadas en distancias. Así la similitud o diferencia entre dos puntos x_k y x_l puede interpretarse como la distancia entre esos puntos.

Una distancia entre dos objetos cualesquiera x_k y x_l es una función que toma valores reales $d: X \times X \rightarrow R^+$ cumpliendo:

$$d(x_k, x_l) = d_{kl} \geq 0; d_{kl} = 0 \equiv x_k = x_l; d_{kl} = d_{lk}; d_{kl} \leq d_{kj} + d_{jl} \quad (1)$$

La partición del conjunto $X = \{x_1, x_2, \dots, x_n\}$ puede enfocarse desde dos perspectivas *fuzzy* y no *fuzzy*. Una partición no *fuzzy* se conoce en la terminología inglesa como “*crisp*”. Si se desea hacer la partición del conjunto X en c clústeres tendremos $S_i = \{i = 1, \dots, c\}$ subconjuntos. A partir de esta consideración se define lo que se conoce como grado de pertenencia u_{ik} de cada objeto al subconjunto S_i que es el valor que toma la llamada función de membresía. En el caso *crisp* un objeto x_k se dice que pertenece a un S_i dado y no pertenece al resto. Esto se expresa con los valores discretos $\{0,1\}$ de la siguiente forma $u_{ik} = 1$ para indicar que pertenece y $u_{ik} = 0$ para indicar que no pertenece. Por el contrario, en el caso de conjuntos *fuzzy* se dice que un objeto puede pertenecer a diferentes subconjuntos y así se habla por ejemplo de que x_k pertenece a un subconjunto S_i con un grado de pertenencia u_{ik} y a S_j con un grado de pertenencia u_{jk} .

Como ejemplo, supongamos que se tienen tres subconjuntos S_i, S_j, S_h , en este caso podríamos decir que el objeto x_k pertenece a los conjuntos con los siguientes grados de pertenencia $u_{ik} = 0.4$, $u_{jk} = 0.5$ y $u_{hk} = 0.1$. Los valores dados corresponden al intervalo continuo $[0,1]$.

Dado $X = \{x_1, x_2, \dots, x_n\}$ y el conjunto V_{cn} de todas las matrices reales de dimensión $c \times n$, con $2 \leq c \leq n$, se puede obtener una matriz representando la partición de la siguiente manera $U = \{u_{ik}\} \in V_{cn}$. Tanto el en supuesto *crisp* como en el *fuzzy* se deben cumplir las condiciones definidas en la ecuación (2)

1. $u_{ik} \in \{0,1\}$ *crisp* $\vee u_{ik} \in [0,1]$ *fuzzy* $1 \leq i \leq c, 1 \leq k \leq n$
2. $\sum_{i=1}^c u_{ik} = 1, 1 \leq k \leq n$ (2)
3. $0 < \sum_{k=1}^n u_{ik} < n, 1 \leq i \leq c$

Para ilustrar los conceptos anteriores sea $X = \{x_1, x_2, x_3\}$ con él podríamos construir las siguientes particiones teniendo en cuenta que $c = 2$.

Crisp

$$U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 1 & 0 & 0 \\ 0 & 1 & 1 \end{bmatrix}$$

$$U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$

Fuzzy

$$U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 0.3 & 0.5 & 0 \\ 0.7 & 0.5 & 1 \end{bmatrix}$$

$$U = \begin{bmatrix} x_1 & x_2 & x_3 \\ 0.9 & 0.4 & 0.2 \\ 0.1 & 0.6 & 0.8 \end{bmatrix}$$

La localización de un clúster específico S_i se representa por su centro $v_i = \{v_{i_1}, v_{i_2}, \dots, v_{i_p}\} \in \mathbb{R}^p$ con $i = 1, \dots, c$, alrededor del cual se concentran los objetos.

La definición básica de llevar a cabo el problema de la partición *fuzzy* para $m > 1$ consiste en minimizar la siguiente función objetivo según la ecuación:

$$\min z_m(U; v) = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m \|x_k - v_i\|_G^2 \quad (3)$$

Donde G es una matriz de dimensión $p \times p$ que es simétrica y definida positiva. Así se puede definir una norma general del tipo,

$$\|x_k - v_i\|_G^2 = (x_k - v_i)^t G (x_k - v_i) \quad (4)$$

Diferenciando la función objetivo para v_i suponiendo constante U , diferenciando después para u_{ik} suponiendo constante v y aplicando la condición de que $\sum_{i=1}^c u_{ik} = 1$, se obtiene,

$$v_i = \frac{1}{\sum_{k=1}^n (u_{ik})^m} \sum_{k=1}^n (u_{ik})^m x_k \quad i = 1, \dots, c \quad (5)$$

$$u_{ik} = \frac{\left(\frac{1}{\|x_k - v_i\|_G^2} \right)^{2/(m-1)}}{\sum_{j=1}^c \left(\frac{1}{\|x_k - v_j\|_G^2} \right)^{2/(m-1)}} \quad i = 1, \dots, c; k = 1, \dots \quad (6)$$

El exponente m se conoce como peso exponencial y disminuye la influencia del ruido al obtener los centros de los clústeres, reduciendo la influencia de los valores pequeños de u_{ik} (puntos lejos de v_i) frente a valores alto de u_{ik} (puntos cerca de v_i). Cuanto mayor sea $m > 1$, mayor resulta dicha influencia.

3.2.1.1. Algoritmo de Agrupamiento c-medias fuzzy

Uno de los más conocidos algoritmos para el agrupamiento borroso es el algoritmo conocido como c-medias fuzzy (Pajares y Cruz, 2011) para obtener el valor de las expresiones (5) y (6) y que se detalla a continuación:

1. Elegir c ($2 \leq c \leq n$), m ($1 \leq m \leq \infty$) y la matriz G de dimensión $p \times p$ siendo simétrica y definida positiva. Inicializar $U^{(0)}$ y poner $t = 0$.
2. Calcular los c centros fuzzy de los clústeres a partir de (5) $\{v_i^{(t)}\}$ utilizando $U^{(t)}$.
3. Calcular los nuevos grados de pertenencia de la matriz $U^{(t+1)}$ utilizando $\{v_i^{(t)}\}$ a partir de la condición (6) si $x_k \neq v_i^{(t)}$. De lo contrario,

$$u_{jk} = \begin{cases} 1, & j = i \\ 0, & j \neq i \end{cases} \quad (7)$$

4. Elegir una norma matricial y calcular $\Delta = \|U^{(t+1)} - U^{(t)}\|_G$. Si $\Delta > \varepsilon$ poner $t = t + 1$ y regresar al paso 2, de lo contrario detener el proceso.

Especial mención requiere la matriz G que determina la forma del clúster. Si se elige la norma euclídea, entonces G es la matriz identidad I y la forma de los clústeres se asume que constituyen una hiper-esfera. G también se puede elegir como una matriz diagonal con $G_D = [\text{diag}(\sigma_j^2)]^{-1}$ o la norma de Mahalanobis con $G_M = [\text{cov}(x)]^{-1}$, donde σ_j^2 denota la varianza de la característica j y cov la covarianza.

3.2.1.2. Índices de Validación de clústeres fuzzy

Existen diferentes medidas escalares para validar la partición, siendo el objetivo encontrar el número de clústeres que obtenga las mejores medidas. Consideraremos, el Coeficiente de Partición (CP), el Coeficiente de Entropía (CE), el Índice de Partición (SC), el Índice de Separación (S) y el Índice de Dunn (DI), todos ellos descritos en (Pajares y Cruz, 2011).

Coeficiente de Partición (CP)

Este coeficiente mide la cantidad de solapamiento entre los clústeres, cuanto más próximo sea este valor a la unidad, tanto mejor será la clasificación, llegando a ser una partición pura cuando toma el valor de la unidad.

$$CP = \frac{1}{n} \sum_{i=1}^c \sum_{j=1}^n (u_{ij})^2 \quad (8)$$

Coeficiente de Entropía (CE)

La entropía es una medida del contenido de información o de cuán organizado es un sistema, en términos de teoría de la información, se asume que hay s posibles símbolos x , por ejemplo letras o dígitos y el símbolo i ocurre con probabilidad $p(x_i)$, entonces la entropía asociada con la fuente del símbolo X está dada por

$$H(X) = -\sum_{i=1}^s p(x_i) \cdot \log(x_i) \quad (9)$$

Donde la entropía viene dada en bits/símbolo si la base de los logaritmos es 2. (Parker, 2011)

Para el caso de los conjuntos difusos encontrados en el algoritmo *fuzzy c-means* este coeficiente viene dado específicamente por,

$$CE = -\frac{1}{n} \sum_{i=1}^c \sum_{j=1}^n u_{ij} \cdot \log(u_{ij}) \quad (10)$$

En este caso, la mejor partición viene dada por aquella que dé el menor valor obtenido para este coeficiente.

Índice de Partición (SC)

Este índice es la razón entre la suma de compacidad y la separación de los clústeres. Se trata de una suma de las medidas de validez de cada clúster individual normalizado por la división de la cardinalidad *fuzzy* de cada clúster N_i ,

$$SC = \sum_{i=1}^c \frac{\sum_{j=1}^n (u_{ij})^2 \|x_j - v_i\|^2}{N_i \sum_{k=1}^c \|v_k - v_i\|^2}, \quad N_i = \sum_{j=1}^n u_{ij} \quad (11)$$

Índice de Separación (S)

Este índice utiliza una distancia mínima para realizar la validez de la separación de las agrupaciones y su valor se calcula con la siguiente expresión:

$$S = \frac{\sum_{i=1}^c \sum_{j=1}^n (u_{ij})^2 \|x_j - v_i\|^2}{nd_{min}^2}, \quad d_{min} = \min_{i,j} (\|v_i - v_j\|) \quad (12)$$

Cuánto más bajo sea el valor de este índice más compacta y separada es la partición.

Índice de Dunn (DI)

Este índice también es utilizado para identificar grupos que sean compactos (compacidad) y bien separados. Su se calcula con la siguiente expresión:

$$DI = \min_{i \in C} \left\{ \min_{j \in C, j \neq i} \left\{ \frac{\min_{x \in C_i, y \in C_j} \|x-y\|}{\max_{k \in C} \left\{ \min_{x, y \in C} \|x-y\| \right\}} \right\} \right\} \quad (13)$$

Obsérvese que el valor del numerador se obtiene como resultado de computar las distancias entre x e y , que son patrones pertenecientes a clústeres distintos C_i y C_j , se trata de una distancia entre clústeres, mientras que en el denominador la distancia es entre patrones x e y , que pertenecen al mismo clúster C . Este índice resulta computacionalmente muy costoso.

Estos índices de validación serán considerados por los mismos motivos descritos en (Sevilla y col., 2016) con respecto a la naturaleza conceptual de los indicadores y su aparente representatividad con algún factor topológico de los clústeres.

3.2.2 K-medias (*K-means*)

El algoritmo de *K-means* (Hartigan y Wong, 1979; Pajares y Cruz, 2007) es un método para hacer de forma automática el agrupamiento de datos de muestras similares. Concretamente, dado un conjunto de n datos $X = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}^p$, se desea agrupar estos datos en unos pocos grupos cohesionados, digamos K , dando lugar a tener el conjunto de agrupaciones $S_k, \{k = 1, \dots, K\}$.

La idea subyacente detrás del método de *K-means* es ejecutar un procedimiento iterativo que se inicia desde unos puntos iniciales elegidos al azar, los llamados centroides y entonces refinar esta elección repitiendo la asignación de muestras al centroide más cercano, para luego proceder a calcular el nuevo valor del centroide del grupo en base a los puntos previamente asignados. La figura 5 muestra un ejemplo ilustrativo de la evolución de los centroides para los datos dados, que forman tres grupos y con un máximo número de iteraciones de diez.




Figura 5. Algoritmo *K-means*, ejemplo de evolución de las iteraciones y determinación de los centroides finales, número de grupos igual a 3 y máximo de iteraciones igual a 10

El algoritmo *K-means* generalmente converge a algún conjunto final de promedios para los centroides de los grupos solicitados para el conjunto de datos de entrada, hay que indicar sin embargo, que la solución encontrada no siempre resulta la solución ideal, puesto que ésta depende del conjunto inicial de centroides seleccionados al azar; por este motivo, en la práctica el algoritmo es usualmente ejecutado varias veces, esto es un determinado máximo número de iteraciones, con diferentes inicializaciones aleatorias para los centroides. (Pajares y Cruz, 2007)

El algoritmo de *K-means* es el siguiente:

1. Obtener los K centroides iniciales de manera aleatoria a partir del conjunto de datos de entrada dado X .
2. Mientras no se alcance el número máximo de iteraciones hacer
 - 2.1. Asignar o asociar X_i al grupo (centroide) más cercano $S_k, \{k = 1, \dots, K\}$
 - 2.2. Computar el nuevo centroide representante de cada grupo $S_k, \{k = 1, \dots, K\}$
 - 2.3. Si los nuevos centroides son distintos a los centroides previos ir a 2.1
3. Si el número de iteraciones es menor al máximo de iteraciones ir a 2, sino terminar.

En la fase de "asignación a grupo" del algoritmo de *K-means*, esto es el proceso de encontrar el centroide más cercano, el algoritmo asigna cada ejemplo de entrenamiento X_i a su centroide más cercano, dada la actual posición para el centroide. Específicamente, para cada ejemplo i lo que hacemos es:

$$k_i \leftarrow k, \min(\|x_i - u_k\|^2) \quad (14)$$

Donde k_i es el índice del centroide que está más cercano al ejemplo X_i y u_k es la ubicación, posición o valor del k -ésimo centroide.

La segunda fase del algoritmo, dadas las asignaciones de cada punto de entrada a algún centroide, vuelve a calcular, para cada grupo el nuevo punto medio o centroide que le será asignado, específicamente para cada centroide se hace el siguiente cálculo:

$$u_k = \frac{1}{|S_k|} \sum_{i \in S_k} X_i \quad (15)$$

Donde $|S_k|$ es el número de elementos de entrada del conjunto de ejemplos de entradas que fueron asignados al centroide (grupo) k .

3.2.3 Cuantización Vectorial

Dado un conjunto de n datos $X = \{x_1, x_2, \dots, x_n\} \in \mathbb{R}^p$, esto es, de dimensión p , se desea agrupar estos datos en unos pocos grupos cohesionados.

Este algoritmo asume que el número de clases no se conoce inicialmente. Por tanto, se comienza suponiendo que hay una única clase y un valor de referencia para la distancia de separación máxima permitida entre los datos de entrada, T , el algoritmo progresa como sigue:

1. Para cada patrón se calcula su distancia d , con todos los centros existentes, para el primer elemento él mismo constituye el primer centro.
2. Se toma el centro más cercano utilizando una medida de distancia, por ejemplo la euclídea, obteniendo $d_{min} = \min(d)$.
3. Si dicha distancia es menor que un valor de umbral previamente determinado, esto es $d_{min} < T$, se asocia el elemento a la clase y se calcula la media de todos los elementos que pertenecen a dicha clase. Esta media nos proporciona el nuevo centro.
4. Por el contrario, si la distancia es mayor que el umbral prefijado $d_{min} > T$, se crea una nueva clase, asignando como valor del centroide del nuevo grupo, los datos del elemento.

3.2.4 Mean Shift (Desplazamiento hacia la media)

3.2.4.1 Introducción

Mean Shift o desplazamiento hacia la media, es un método no paramétrico para el procesamiento y análisis de una muestra de datos en un espacio de características que fue presentado por (Fukunaga, 1975), que mucho tiempo después fue estudiado por (Cheng, 1995) para la temática específica del análisis y procesamiento de imágenes y ampliamente desarrollado después por (Comaniciu, 2002) para problemas de procesamiento de imágenes y visión artificial como son la agrupación, segmentación y seguimiento de objetos en video.

El algoritmo de *Mean Shift* parte del procedimiento bien conocido de las Ventanas de Parzen en donde a partir de una muestra de puntos de un espacio de características p -dimensional determinado, obtiene una función de densidad de probabilidad (PDF) estimada para dicha muestra. Esta función a su vez presenta máximos locales en regiones densas de puntos (modas) y valores más bien pequeños en regiones menos pobladas de puntos, motivo por el cual el procedimiento de *Mean Shift* es utilizado de forma iterativa para obtener los máximos locales de la PDF, estimando de forma iterativa el gradiente de la función de densidad, los puntos encontrados representan puntos característicos o de interés del análisis de los datos.

Para las imágenes de vegetación, (Liying Zheng y col. 2009), proponen un algoritmo, introduciendo el *Mean Shift* en el algoritmo de segmentación. El algoritmo resultante consta de dos fases, en la fase inicial se extraen características, como el tono y la saturación en el espacio HSI, o los colores rojo, verde y azul del espacio RGB. En la segunda fase se realiza la segmentación de la imagen con las características extraídas, mediante *Mean Shift* y una red neuronal “*back propagation*”, de esta forma la imagen es clasificada en dos, la parte de vegetación verde y la no verde. Esta combinación de algoritmos genera buenos resultados, si bien según sus autores no es adecuada para ser utilizada en aplicaciones de tiempo real.

3.2.4.2 Descripción del Algoritmo *Mean Shift*

El algoritmo de *Mean Shift* es uno de los métodos de estimación de la función de densidad, que también puede ser conceptualizado como basado en la determinación de un *kernel* o núcleo de densidad. Dado un conjunto de datos $X = \{x_1, x_2, \dots, x_n\} \in \mathbf{R}^p$ un subconjunto de datos del espacio real p-dimensional \mathbf{R}^p , el estimador del *kernel* de densidad multivariado utilizando el *Kernel* $K(x)$ con ancho de banda h , es:

$$\hat{f}(x) = \frac{1}{nh^p} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (16)$$

El objetivo de esta función de *Kernel* es el de poder definir un elemento que permita expresar en alguna medida la similitud entre dos conjuntos de datos. Los *kernels* que más se utilizan son los que son definidos como una función que es radialmente simétrica y caracterizados por su perfil $k_N(x)$, lo que lleva a la usar *kernels* isotrópicos, esto es que procesa o analiza por igual la vecindad del punto x como por ejemplo el *kernel* gaussiano, que es definido por la siguiente expresión,

$$K_N(x) = (2\pi)^{-p/2} e^{-\frac{1}{2}\|x\|^2} \quad (17)$$

Además, para todo *kernel* radialmente simétrico, como el *kernel* normal, se establece las siguientes propiedades:

$$\begin{aligned} \int_{\mathbf{R}^p} K(x) dx &= 1 \text{ (Es normalizado)} & \int_{\mathbf{R}^p} xK(x) dx &= 0 \text{ (Es simétrico)} \\ \int_{\mathbf{R}^p} xx^t K(x) dx &= c_k I \text{ (Es no correlacionado)} & \lim_{\|x\|^p \rightarrow \infty} \|x\|^p K(x) &= 0 \text{ (Decae exponencialmente)} \end{aligned}$$

Además, el perfil del núcleo gaussiano viene dado por la siguiente expresión:

$$k_N(x) = e^{-\frac{1}{2}x} \quad (18)$$

El primer paso en el análisis de los datos de entrada y con función de densidad $f(x)$ es encontrar los puntos de mayor concentración de datos, esto es las modas de esta función. Para determinar estos puntos, se puede encontrar la función gradiente y estimar los valores que son iguales a cero, esto es $\hat{\nabla}f(x) = 0$.

Se denomina *Mean Shift* o desplazamiento hacia la media, al desplazamiento desde un punto inicial \mathbf{x} en el espacio de datos de entrada hacia otro punto que resulta del promedio de los pesos de los datos s , dentro de una vecindad determinada por una región S centrada en \mathbf{x} . Los pesos asociados a los datos dentro de la región quedan determinados por la función *kernel* K , mediante la siguiente expresión:

$$m_K(x) = \frac{\sum_{s \in S} K(s-x)s}{\sum_{s \in S} K(s-x)} - x \quad (19)$$

El numerador del cociente del lado derecho de la ecuación es la suma ponderada de cada uno de los datos dentro de la región centrada en x , mientras que el denominador determina el valor esperado. El vector desplazamiento $m_K(x)$ queda entonces determinado como la diferencia entre el punto de mayor densidad de datos y el punto de inicio x .

Estimando el gradiente de la función $\hat{f}(x)$, teniendo en cuenta por definición que $K(x) = c_{k,p}k(x)$ se obtiene la siguiente expresión:

$$\hat{\nabla}f_{h,K}(x) = \frac{c_{k,p}}{nh^p} \sum_{i=1}^n k'(\|\frac{x-x_i}{h}\|^2) = \frac{2c_{k,p}}{nh^{p+2}} \sum_{i=1}^n (x-x_i)k'(\|\frac{x-x_i}{h}\|^2) \quad (20)$$

Si se define un nuevo perfil $g(x) = -k'(x)$ y se continúa el desarrollo matemático correspondiente, se obtiene finalmente la siguiente expresión:

$$\hat{\nabla}f_{h,K}(x) = \frac{2c_{k,p}}{nh^{p+2}} \sum_{i=1}^n (x-x_i)g(\|\frac{x-x_i}{h}\|^2) \quad (21)$$

$$\hat{\nabla}f_{h,K}(x) = \frac{2c_{k,p}}{nh^{p+2}} \left[\sum_{i=1}^n g(\|\frac{x-x_i}{h}\|^2) \right] \left[\frac{\sum_{i=1}^n x_i g(\|\frac{x-x_i}{h}\|^2)}{\sum_{i=1}^n g(\|\frac{x-x_i}{h}\|^2)} - x \right] \quad (22)$$

Expresión donde el primer término, al que llamaremos \hat{f} corresponde a la estimación de la función de densidad en x con el nuevo núcleo $G(x)$ y el segundo término denominado $m_{h,G}$ se corresponde con el vector desplazamiento *Mean Shift*. Este vector desplazamiento apunta siempre en la dirección de incremento máximo de la función de densidad, por lo que su

desplazamiento se realizará hacia la vecindad de mayor concentración de datos, esto es a la moda que estamos buscando.

La figura 6 muestra un esquema de funcionamiento del algoritmo, la tarea es ajustar el *kernel*, denotado por los círculos en la figura indicada, es decir mover su centro, de manera que pueda contener más puntos dentro de él. Así, si el *kernel* comienza como en el círculo verde en la parte inferior derecha de la imagen, después de su primera iteración puede terminar en la posición del círculo naranja, hasta que eventualmente y luego de seguir moviéndose llegue a la ubicación del círculo rojo, donde se entiende se logra la convergencia.

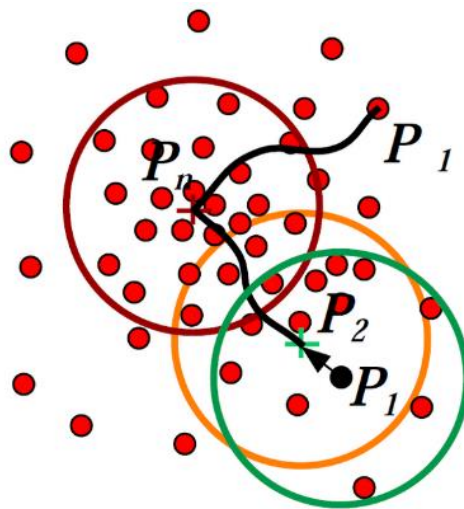


Figura 6. Visión instantánea del Procedimiento de Mean Shift

El procedimiento de *Mean Shift* se sintetiza de la siguiente manera:

1. Calcular el vector de desplazamiento *Mean Shift*, a partir de un punto x dado del espacio de características y considerando la región definida por el *kernel* correspondiente.
2. Correr o desplazar el centro de la ventana o *kernel* al punto determinado por el vector de desplazamiento.
3. Si la norma del desplazamiento es menor que un valor de incremento de variación previamente determinado terminar el proceso, sino ir al paso 1.

De esta manera los pasos descritos se pueden reformular mediante una expresión de iteración de punto fijo, como la siguiente:

$$x_{i+1} = x_i + m_h(x_i) \quad (23)$$

Existen situaciones donde el procedimiento propuesto no alcanza un máximo local, por ejemplo en el caso de encontrar una meseta o punto de ensilladura, donde convergerá, pero

no a lo esperado. *Mean Shift* alcanzará un máximo en tanto se tenga garantía de que en cada iteración exista un único punto de mayor densidad de datos dentro del entorno determinado por el ancho del *kernel* utilizado, lo cual se consigue para todo *kernel* convexo con perfil monótonamente decreciente.

Existe ciertas ventajas adicionales al elegir cuidadosamente el *kernel*, por ejemplo, eligiendo el *kernel* gaussiano como ventana, se obtiene un camino o trayectoria suave hasta encontrar la moda, esto es el ángulo entre dos vectores *Mean Shift* consecutivos es siempre menor que 90° , lo que aumenta la velocidad de convergencia. (Comaniciu, 2002)

Una consideración final debe ser tenida en cuenta, que tiene que ver con la elección del tamaño de la ventana o también conocido como parámetro del ancho de banda para ser utilizado en la función de *kernel*, este tamaño influye en la manera en que cada uno de los datos de la muestra de entrada ajusta la función de densidad resultante.

Existen cuatro técnicas diferentes enumeradas en el trabajo de (Comaniciu, 2002) para la selección del parámetro ancho de banda (*bandwidth*) h utilizado en la función *kernel* para el procedimiento *Mean Shift*, a saber:

- Selección estadística: es el ancho de banda que alcanza el mejor compromiso entre el sesgo y la varianza del estimador sobre todos los $x \in R^p$ aquel que minimiza la medida AMISE (*Asymptotic Mean Integrated Square Error*), diferencia cuadrática entre lo estimado y lo real.
- Por estabilidad de la descomposición: el *bandwidth* es la media del rango sobre el cual se obtuvo el mismo número de clústeres para diferentes experimentos.
- *Bandwidth* máximo: es el mejor *bandwidth* que maximiza una función objetivo que expresa la calidad de descomposición. La función objetivo estudia por lo general la variabilidad que se tiene inter-intra clústeres o conectividad-aislamiento entre ellos.
- Información de alto nivel: como en muchos de los casos la descomposición depende de la tarea a realizar, se puede tomar el *bandwidth* de la información dada por el usuario o por niveles altos de la tarea.

Una inapropiada elección del *bandwidth* puede causar la unión de modas significativas en un contexto en particular o generar otras no representativas. Por lo antes expuesto, la elección de un tamaño de ancho de banda para el *kernel* correcto no es una tarea trivial.

3.2.5 Redes neuronales

Las redes neuronales artificiales son estructuras paralelas inspiradas en las neuronas biológicas. Una red neuronal está compuesta por multitud de elementos más simples, llamados neuronas, interconectados de una forma más o menos densa y cuyo funcionamiento en conjunto puede dar lugar a un procesamiento no lineal complejo. Las redes son capaces de ajustar su comportamiento a partir de datos experimentales y en base a alguna figura de mérito de modo que son muy útiles en problemas donde el conocimiento del problema es incompleto o varía en el tiempo. (Pajares y Cruz, 2011)

Las ventajas de las redes neuronales artificiales, como sistemas de aprendizaje, son diversas, las más destacadas se detallan a continuación:

- Aprendizaje adaptativo, capacidad de aprender a realizar tareas basadas en la experiencia a partir de un entrenamiento con datos parciales.
- Auto organización, la red puede crear su propia organización o su propia representación de los datos después de una etapa de aprendizaje, esta representación se basa en datos utilizados para el aprendizaje.
- Tolerancia a fallos, una destrucción parcial de la red conduce a una degradación de los resultados pero, en muchos casos, la red puede seguir funcionando.
- No linealidad, la neurona realiza, en general, una transformación no lineal de su entrada, la combinación de las distintas neuronas podrá representar funciones no lineales.

3.2.5.1 El proceso de aprendizaje

Una de las características más importantes de las redes neuronales es su capacidad de aprendizaje, esto es, la posibilidad de modificar los parámetros para adaptarse a la interacción con una entrada proporcionada por el medio que las rodea. (Pajares y Cruz, 2011)

Según sea la forma de adaptación nos referiremos a un determinado tipo de aprendizaje u otro, en general, el proceso de aprendizaje implica un estímulo o interacción de la red con el medio y un ajuste de sus parámetros mediante un algoritmo concreto.

La interacción de la red con el medio se la conoce como tipo de aprendizaje o paradigma, entre los más importantes se puede destacar el aprendizaje supervisado, el aprendizaje por refuerzo y el aprendizaje no supervisado.

3.2.5.1.1 Algoritmo de aprendizaje

Los algoritmos de aprendizaje tratan de buscar la forma de modificar los parámetros de la red para que el funcionamiento de ésta sea semejante a lo que se busca. Normalmente los parámetros a modificar son los pesos de las conexiones definidas entre las neuronas y la forma de cómo se realiza la modificación dependerá del modo en que se desea que la red aprenda.

En los algoritmos de aprendizaje se conoce como error a la diferencia que existe entre la salida que proporciona la red y la salida que se espere proporcione. Modificar los parámetros de la red para que disminuya este error es la forma más clara de intento para que la red aprenda. El objetivo para el aprendizaje será minimizar el error en todas las neuronas de salida, para esto se puede definir una función de coste, por lo que el problema del aprendizaje se reduce a un problema de optimización.

$$J(k) = E \left[\frac{1}{2} \sum_{n=0}^N (d_n(k) - y_n(k))^2 \right] \quad (24)$$

La regla de Hebb es otro algoritmo de aprendizaje, en este caso se intenta que la red aprenda siguiendo el mecanismo biológico, fue propuesta por (Hebb, 1949). Mantiene que cuando dos neuronas están conectadas y están activas simultáneamente el peso sináptico que las une debería reforzarse, pero que cuando una neurona está activa y la otra inhibida, su peso debería disminuir.

$$\Delta w_{ij} = \alpha \cdot x_i(k) \cdot y_j(k) \quad (25)$$

El mayor problema de la ecuación anterior es que los pesos w_{ij} crecen indefinidamente y por lo tanto se hace necesario fijar un límite, esto es establecer un nivel de saturación. Una forma sencilla de evitar este crecimiento ilimitado consiste en añadir un factor de olvido, de esta forma obtenemos la regla de Oja (Oja y col., 1992) que mantiene los pesos acotados en torno al valor de la unidad,

$$\Delta w_{ij} = \alpha \cdot y_j(k) \cdot (x_i(k) - y_j(k) \cdot w_{ij}(k)) \quad (26)$$

En el algoritmo competitivo, las neuronas de la capa de salida se conectan entre sí y compiten entre ellas de forma que se inhiben unas a otras, siendo la ganadora la que inhibe. De este modo, para cada entrada de una muestra sólo queda una neurona activa, que es la que representará al patrón de entrada. Este tipo de aprendizaje, que se denomina “el ganador toma todo” es muy útil para encontrar patrones, agrupaciones de características, como el del

problema de la investigación, siendo la neurona vencedora la que detecta y representa la característica del grupo.

El algoritmo está orientado a que la neurona ganadora actualice sus pesos de forma que aprenda las características del patrón de la entrada. Bajo esta consideración, el procedimiento de aprendizaje es el que aparece en la ecuación:

$$\Delta w_{ij} = \begin{cases} \alpha(x - w_{ij}) & \text{si la neurona } j \text{ vence} \\ 0 & \text{si la neurona } j \text{ NO vence} \end{cases} \quad (27)$$

A partir de (27) se puede ver que los pesos entre las neuronas de entrada y la neurona ganadora tienden a tomar el mismo valor que la entrada x , estando la velocidad de la tendencia controlada por el factor α .

3.2.5.1.2 Redes SOM

La estructura básica de una red de aprendizaje competitivo en general consta de dos capas de neuronas:

- Una capa de entrada, que recibe los datos y mide de alguna manera la similitud entre esta entrada y los pesos almacenados en la red;
- Una capa de salida, con neuronas competitivas que tienen conexiones inhibitoras entre ellas del tipo “el ganador toma todo”, como ya se mencionó en la sección 3.2.5.1.

Las neuronas de entrada para comparar su conocimiento almacenado con respecto a la nueva entrada utilizan una medida de similitud, siendo habitual el uso de distancias entre el vector de entrada y el vector de pesos almacenados en cada neurona. El vector de entrada, una vez ha superado la capa de similitud, llega a la capa competitiva en el instante inicial, siendo posteriormente retirado; este impulso representa la condición inicial para que las neuronas iteren hasta que solo una quede como vencedora.

La neurona de salida, la única cuya salida no es cero, sino uno, identifica el grupo o clase al que pertenece el patrón de entrada entregado. Estas neuronas tienen una realimentación unitaria y una conexión inhibitora con todas las demás.

Entre los años 1982 y 1990, Kohonen definió los mapas auto-organizados, SOM, *Self Organizing Maps*, estas redes también son inspiradas en redes neuronales biológicas. Se ha observado que en el córtex cerebral de los animales superiores aparecen zonas donde las

neuronas detectoras de rasgos similares se encuentran topológicamente ordenadas en zonas y cuando se recibe un estímulo se activan neuronas próximas entre sí. (Kohonen, 1984; Kohonen, 1990)

Para emular el comportamiento del córtex cerebral, los mapas auto-organizados se diseñan de forma que cuando un conjunto de datos de entrada se presenta a la red, los pesos de las neuronas se adaptan de forma que la clasificación implícita presente en el espacio de entrada se preserva a la salida. Así, la red construye un mapa de las entradas que le son mostradas de forma que extrae las características y relaciones más importantes, básicamente las SOM pueden implementar dos funcionalidades:

- Análisis de datos, por auto asociación, actuando como clasificadores encontrando patrones en los datos de entrada y clasificándolos en grupos según estos patrones.
- Asistencia a la clasificación o a la predicción, representando datos multidimensionales en espacio de mucha menor dimensión, normalmente uno o dos dimensiones, preservando la topología de la entrada.

A partir de estas dos funcionalidades base se pueden definir otras para aplicaciones como, por ejemplo, optimización, predicción, clasificación o compresión de datos con pérdida.

3.2.5.1.3 Arquitectura de las Redes SOM

La red SOM tiene básicamente la estructura general que se ha indicado en la sección anterior, una capa de entrada que se encarga de establecer la similitud de los datos y otra capa competitiva en la que el algoritmo está orientado a que la neurona ganadora actualice sus pesos de forma que aprenda las características del patrón de la entrada.

Debido a que estas redes permiten construir mapas de características a partir de los datos de entrada, es especialmente importante la disposición de las neuronas de salida. Normalmente las neuronas de la capa de salida se organizan de forma bidimensional en un plano, si bien se pueden organizar en otras estructuras como la mono dimensional (en línea), en cilindro, en toroide, entre otras, figura 7. El utilizar diferentes topologías de las neuronas de salida no afecta a la funcionalidad de la red pero si al aprendizaje y al resultado obtenido, por lo que conviene que dichas estructuras reflejen propiedades del espacio de entrada.

Téngase en cuenta que, aunque las conexiones entre las neuronas de la capa de salida dependen de la topología, las neuronas de entrada siempre se conectan a todas las neuronas de la capa de salida.

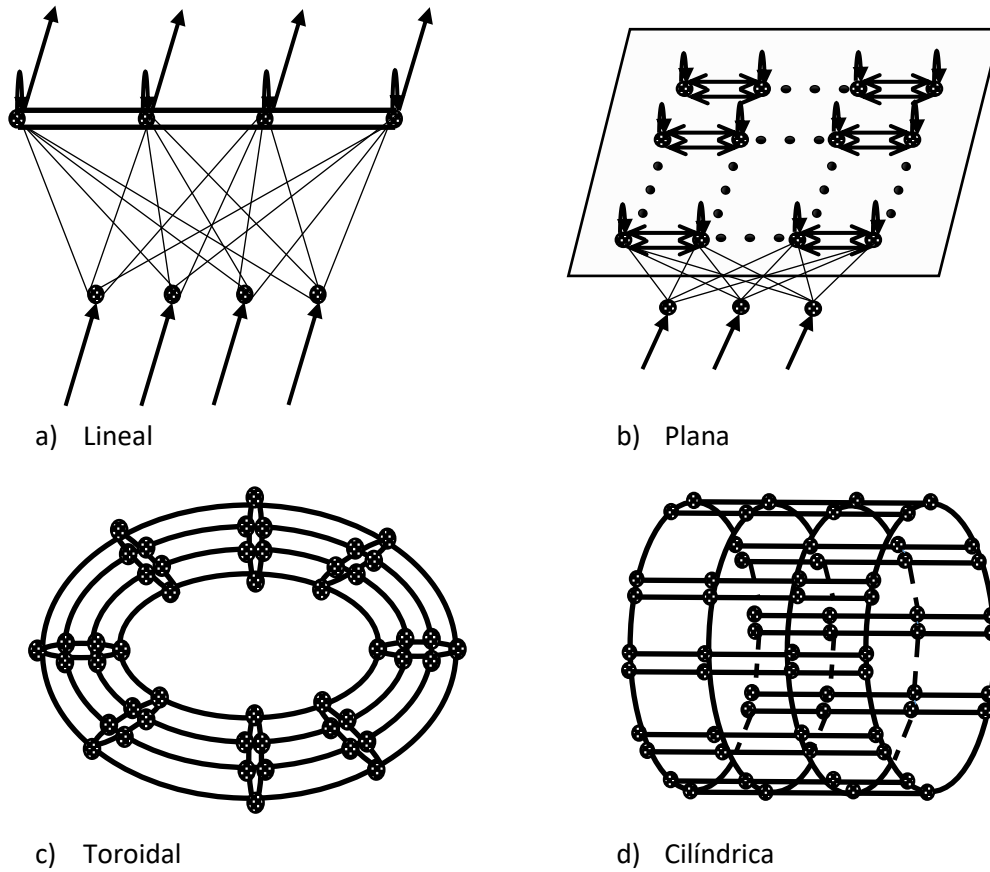


Figura 7. Distintas topologías para las neuronas de salida en redes SOM

3.2.5.1.4 Algoritmo de aprendizaje de las Redes SOM

Inicialmente los pesos entre las neuronas de entrada y los pesos de las neuronas de salida se inicializan aleatoriamente, el aprendizaje comienza cuando se le muestra un patrón a la red en la capa de entrada, en este momento se propaga el patrón de entrada a la capa de salida y la función de activación de cada neurona de salida calcula la proximidad o similitud del patrón de entrada con el patrón almacenado en sus pesos, quedando activa la neurona ganadora, esto es la que más se aproxime al valor de entrada.

Para medir el grado de similitud se suele utilizar una medida de distancia entre los dos vectores, siendo las más comunes:

La distancia Euclídea,

$$D(x, w_j) = \sqrt{\sum_{i=1}^{n_s} (x_i - w_{ij})^2} \quad (28)$$

La distancia Minkosky,

$$D(x, w_j) = \sqrt[k]{\sum_{i=1}^{n_s} (x_i - w_{ij})^k} \quad (29)$$

La distancia de Mahalanobis,

$$D(x, w_j) = \sum_{i=1}^{n_s} |x_i - w_{ij}| \quad (30)$$

Como en cualquier proceso de aprendizaje se pretende que la neurona ganadora se parezca más al patrón mostrado, por lo que aplicaremos un algoritmo de aprendizaje competitivo como el definido en la expresión (27), en esta expresión la velocidad de aprendizaje α , indica la cantidad de la diferencia entre el patrón y los pesos de la neurona ganadora, se aproxima en cada iteración. Este proceso se repite para todos los patrones una serie de veces de modo que la salida finalmente reconoce las clases en las que puede dividirse el espacio de entrada.

3.2.5.1.5 Función de vecindad de las Redes SOM

Las redes SOM deben su nombre al hecho de que, no sólo es capaz de detectar el representante de una clase, sino que, al igual que se observa en el cerebro, es capaz de mostrar un mapa bidimensional, dependiendo de la topología de la capa de salida, que representa las características mostradas, de esta manera, no sólo se obtiene el representante, sino que también es posible extraer la estructura de los datos de entrada y la importancia relativa de cada uno de ellos.

Para conseguir este efecto, se introduce la función de vecindad ρ , que define la influencia de una neurona sobre sus vecinas. De esta manera, cuando se modifican los pesos de la neurona ganadora se modifica también, en la medida indicada por la función de vecindad, los pesos de todas las neuronas vecinas, la expresión siguiente representa esta influencia,

$$\Delta w_j = \rho(i, j) \cdot \alpha \cdot (x - w_j) \quad (31)$$

Con esta expresión se consigue que los pesos de las neuronas cercanas a la ganadora sean similares a los de ésta, similitud que disminuye progresivamente a medida que nos alejamos de la neurona vencedora, esto permite ordenar de manera topológica la red, obteniendo regiones de patrones similares.

El uso de esta función aporta dos ventajas importantes en el algoritmo, primero el ritmo de la convergencia mejora, y segundo el proceso se vuelve más robusto frente a variaciones de los pesos iniciales. Finalmente, la función de vecindad ρ , debe ser simétrica respecto de la

ubicación de la neurona ganadora, para no favorecer a una dirección en concreto, siendo una de la más utilizada la función gaussiana. (Pajares y Cruz, 2011)

3.2.5.1.6 Proceso de aprendizaje de las Redes SOM

El proceso de aprendizaje de una red SOM consta de dos fases claramente definidas, una fase de ordenación y otra fase de convergencia.

La fase de ordenación consiste en la ubicación topológica de los vectores que representan a las clases existentes en la entrada. Para este propósito, se utiliza al inicio una combinación de velocidad de aprendizaje alta y función de vecindad amplia con respecto a la neurona ganadora, esto permite que las neuronas de salida se vayan reubicando y agrupando en las clases detectadas en el proceso. Para que esta fase llegue a la convergencia, esto es, los pesos lleguen a estabilizarse en torno a algún valor, se requiere que la velocidad de aprendizaje y el ancho de la vecindad reduzcan sus valores a valores lo suficientemente pequeños, que impidan que se desorganicen las neuronas ya ordenadas.

La velocidad de aprendizaje puede disminuirse desde un valor inicial (α_0) a un valor final (α_f) de forma lineal o exponencial, como en las expresiones a continuación, en las que en cada iteración k se reduce α hasta llegar al valor final, en la que finalizará la fase de convergencia.

$$\alpha(k) = \alpha_0 + (\alpha_f - \alpha_0) \frac{k}{k_f} \quad (32)$$

$$\alpha(k) = \alpha_0 \cdot (\alpha_f/\alpha_0)^{k/k_f} \quad (33)$$

En cuanto a la función de vecindad, según Pajares y Cruz (2011) se suele modificar algún parámetro de ésta, relacionado con la forma de la función, por ejemplo, si se usa la función gaussiana se modifica la varianza para que se estreche cada vez más en cada iteración, de modo que llegue a ser nula la influencia en las neuronas vecinas. La variación del parámetro a modificar, digamos r , suele ser lineal, con una posible variación como la establecida por la ecuación siguiente,

$$r(k) = r_0 + (r_f - r_0) \frac{k}{k_f} \quad (34)$$

La fase de convergencia se encarga de realizar un ajuste fino de los pesos, aquí se persigue que los pesos sinápticos se ajusten lo más posible a la entrada. En esta fase se toma la velocidad de aprendizaje baja, digamos de 0.01 y la vecindad igual a 1. Este proceso, aunque puede también

llegar a ser costoso, conlleva generalmente un menor número de iteraciones que las requeridas en la fase de ordenación.

3.2.6 Índices de Validación de clústeres *crisp*

De conformidad a lo expresado en la sección 2.6, para este estudio se acoge la propuesta establecida en (Sevilla y col., 2016) para la evaluación de los resultados obtenidos en los distintos algoritmos utilizados en agrupamientos *crisp*. Así, se establece que la topología de las clases contenidas en una colección de datos puede ser entendida mediante el cálculo del siguiente conjunto de índices de validación de agrupaciones: Diámetro (Δ), Separación (δ), Calinski-Harabasz (CH), Dunn (D) y Entropía (E).

Dados,

Un conjunto de datos X , compuesto de n individuos o muestras $I = \{i_1, \dots, i_n\}$ y con un conjunto K atributos $X = \{X_1, \dots, X_K\}$.

Un conjunto de particiones $P = \{C_1, \dots, C_j\}$ conteniendo un número ξ de clústeres donde el valor de $nc = \text{card}(C)$, $C \in P$; $C \cap C' = \emptyset$; $C, C' \in P$.

Siendo, $d(i, i') = \sqrt{\sum_{k=1}^K (x_{ik} - x_{i'k})^2}$ la distancia entre dos individuos $i, i' \in I$.

Las definiciones de los índices escogidos son las siguientes.

3.2.6.1 Diámetro máximo del grupo (Δ)

El **Diámetro máximo del grupo (Δ)** es la distancia máxima entre cualesquiera dos puntos que pertenezca al mismo grupo. En otras palabras, se define por el diámetro más alto entre todos los grupos pertenecientes a P . Por lo tanto, mide la compacidad, los valores van desde $[0, 1)$ y lo que se busca es minimizarlo.

$$\Delta = \max_{C \in P} \Delta_c, \quad \Delta_c = \max_{i, i' \in C} d(i, i') \quad (35)$$

3.2.6.2 Separación de Clúster Mínima (δ)

La **Separación de Clúster Mínima (δ)** es la distancia mínima entre cualquiera de dos objetos que no pertenecen al mismo grupo. En otras palabras, se define por la separación inferior entre todos los grupos. Mide la separación, lo que se busca es maximizarlo y los valores varían en $[0, \infty)$; $\delta_{C, C'}$ está estrechamente relacionado con la medida de la brecha máxima WG_C . Y

$\delta_{C,C'}$ encuentra espacios entre clústeres mientras que WG_c encuentra espacios dentro de cada clúster.

$$\delta = \min_{C,C' \in P} \delta_{C,C'}, \delta_{C,C'} = \min_{i \in C, i' \in C'} d(i, i') \quad (36)$$

3.2.6.3 Índice de Calinski-Harabasz (CH)

El **Índice de Calinski-Harabasz (CH)** (Calinski, 1974) se basa en obtener un compromiso entre las distancias entre clúster (separación) y las distancias dentro del clúster (compacidad). Por lo tanto, lo que se busca es maximizarlo y su rango de valores está entre [0,1). El índice **CH** se define como sigue:

$$CH = \frac{BSS/(\varepsilon-1)}{WSS/(n-\varepsilon)}, BSS = \sum_{C \in P} n_c d(i_c - \bar{i})^2 \quad (37)$$

i_c , es el baricentro del grupo **C**, \bar{i} es el baricentro de **I**. El índice **CH** se interpreta como valores más altos como una mejor partición de clústeres.

Además **WSS**, es la suma de cuadrados dentro de los grupos, es la suma de las distancias cuadradas entre todos los pares de objetos dentro de un grupo. Esto mide la compacidad, mejor para minimizar y los valores varían en [0,). Si i_c el baricentro del grupo **C**,

$$WSS = \sum_{C \in P} WSS_c, WSS_c = \sum_{i \in C} d(i, i_c)^2 \quad (38)$$

3.2.6.4 Índice de Dunn (D)

El **Índice de Dunn (D)** es un índice de la validez del grupo para la agrupación *crisp* propuesta en (Dunn, 1974). Intenta identificar "grupos compactos y bien separados". Si un conjunto de datos contiene grupos bien separados, las distancias entre los grupos son generalmente más grandes que los diámetros de los grupos. Presentamos una formulación a partir de 3.2.6.2 para $\delta_{C,C'}$ y 3.2.6.1 para Δ_c . Mide la relación de separación versus compacidad, por lo que se busca es maximizarlo y los valores van desde [0,).

$$D = \frac{\min_{C,C' \in P} \delta_{C,C'}}{\max_{C \in P} \Delta_c} \quad (39)$$

3.2.6.5 Entropía (E)

El **Índice de Entropía (E)** mide, como su nombre indica, la entropía asociada con la partición P, que en definitiva es una medida del orden o desorden de los datos. La entropía es siempre no

negativa y toma el valor 0 sólo cuando no hay incertidumbre (cuando sólo hay un grupo). Por lo tanto, mide el caos, los valores van desde $[0, 1]$ y lo que se busca es minimizarlo.

$$E = -\sum_{C \in P} \frac{n_c}{n} \log\left(\frac{n_c}{n}\right) \quad (40)$$

Obsérvese que la incertidumbre no depende del número de objetos en I sino de las proporciones relativas de los conglomerados.

3.3 Método propuesto

3.3.1 Introducción

De manera general los algoritmos de clasificación descritos en la sección 3.2 correspondiente a la primera parte de los experimentos producen resultados más o menos aceptables a la hora de identificar o segmentar los datos de las imágenes de entradas, resultando sin embargo, poco efectivos los intentos de automatizar el proceso de segmentación y posterior clasificación de una manera eficiente, en el sentido del consumo de recursos y en el sentido de obtener resultados más o menos normalizados, alrededor de los verdaderos valores. Es posible, no obstante, detener el proceso de segmentación con los algoritmos probados con la valoración del resultado que se va obteniendo con alguna medida del error de reconstrucción, por ejemplo en este trabajo mediante el cálculo del error cuadrático medio entre la imagen codificada con los centros detectados por cada uno de los algoritmos y la imagen original. Alternativamente, se puede también proceder mediante la elección de la agrupación que ofrezca los mejores indicadores de validación de clústeres. Por último la labor final de clasificación de una nueva imagen se realiza luego de construida la base de características, para cada uno de los algoritmos mencionados, mediante el uso del algoritmo de *K-means*.

En esta parte de este trabajo, explicaremos el proceso sistemático propuesto y que se muestra en detalle en la figura 8, se puede observar que el proceso está compuesto de cinco pasos fundamentales que se describen a continuación:

- 1) Segmentación gruesa de las imágenes a través de la información cromática de la imagen de entrada, para cada uno de los canales R, G, B.
- 2) Caracterización de las tres imágenes segmentadas obtenidas en el paso 1 por medio del algoritmo SOM.
- 3) Evaluación de las agrupaciones generadas por medio de SOM mediante los índices de validación de clústeres.

- 4) Selección y almacenamiento de las mejores características de las agrupaciones detectadas mediante SOM para las tres imágenes generadas en el paso 1, mediante la aplicación del criterio de voto mayoritario de los CVI.
- 5) Clasificación de las características de la nueva imagen mediante el algoritmo de *K-means* y la base de características generadas por el algoritmo propuesto.

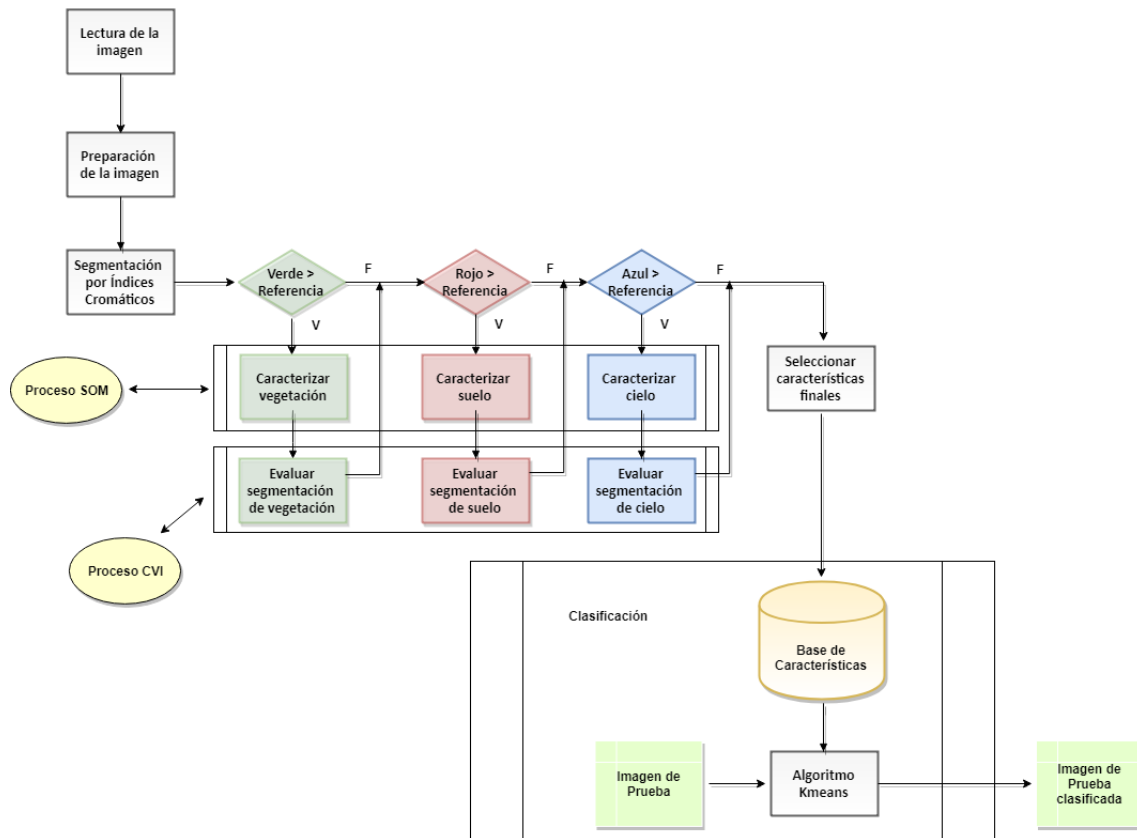


Figura 8. Esquema general del proceso de la investigación realizada

Cabe indicar, que los pasos de captura/lectura de las imágenes en el presente trabajo no han sido desarrollados puesto que se ha utilizado un conjunto de noventa y dos imágenes digitales de campos reales de cultivos de maíz y de cebada, tomadas en un campo experimental en “La Estación de Investigación de Poveda”, Arganda del Rey, Madrid, entre los meses de abril y mayo de 2007. Las imágenes digitales proporcionadas en formato “JPG” tienen un tamaño de 800 x 600 píxeles, capturando imágenes en el espacio de color RGB, con una cámara digital, HPR817. Estas imágenes han sido divididas en dos conjuntos de imágenes de 40 y 52 imágenes, para que se correspondan a los conjuntos de entrenamiento y de prueba, en este último conjunto se incluyen también un conjunto de ochenta imágenes obtenidas de los campos del Ecuador, de la zona agrícola de Balzar y El Empalme, tomadas desde la cámara de un celular Samsung s7 Edge y han sido preparadas previamente para su entrega para el procesamiento en los distintos algoritmos, haciendo una reducción uniforme de su tamaño, hasta que queden

de tamaño 256 x 256 píxeles, para lo cual se ha hecho uso de la función *imresize* del software Matlab.

Por otro lado, la segmentación cromática se ha realizado mediante la aplicación de los índices cromáticos mencionados en la sección 2.4.3, exceso de verde ExG, exceso de rojo ExR y exceso de azules ExB, los cuales se ajustan de buena manera a las necesidades de la solución del problema.

$$\text{Exceso de Verde (ExG)} \quad \text{ExG} = 2g - r - b \quad (41)$$

$$\text{Exceso de Rojo (ExR)} \quad \text{ExR} = 1.4r - g \quad (42)$$

$$\text{Exceso de Azul (ExB)} \quad \text{ExB} = 1.4b - g \quad (43)$$

Con las imágenes segmentadas por cromaticidad, se evalúa su proporción, de conformidad a un valor de referencia, obtenido por experimentación, para luego proceder a la caracterización del elemento correspondiente, esto es vegetación, suelo o cielo, evaluando a continuación las particiones obtenidas y seleccionando la mejor por el método de voto mayoritario de los indicadores de validación de clústeres, seleccionando y almacenando las mejores características que serán utilizadas posteriormente en el algoritmo de clasificación *K-means*.

La idea trascendental es resaltar los aspectos de interés, así como los de no interés a través de la información de cromaticidad, en este tema por su importancia el proceso se muestra con detalle en la figura 9, la que se explica a continuación. Primero se genera la información de cromaticidad, con el propósito posterior de separar o extraer estas porciones de imagen de la imagen original, lo que se muestra en la figura en los pasos de binarización y suavización de la imagen en el canal correspondiente y poder así pasar estos datos al algoritmo SOM para la extracción de características, se entiende con menos ruido, al ser los datos de entrada en general, más uniformes por describir aspectos concretos de la imagen utilizada, a saber la vegetación obtenida por medio del valor de ExG, el suelo obtenido con ExR y el cielo con ExB, destacados como elementos de interés.

A continuación, se procede al cálculo del valor de las normas de estas matrices de imágenes, buscando tener una idea de la cantidad de información presente en cada canal de la imagen de entrada. Un aspecto relevante en este punto es la referencia que se ha determinado para saber si se debe separar la estructura de interés o no interés de la imagen original para su procesamiento por separado, lo cual se realiza con la determinación de la proporción de información cromática resaltada verde, roja, azul. De los diversos experimentos realizados los valores de referencia (umbrales) correspondientes están alrededor de 15, 15 y 17 por ciento

respectivamente, las expresiones utilizadas para calcular las proporciones de píxeles presentes en las matrices de exceso de verde, exceso de rojo o exceso de azul, derivadas desde la imagen de entrada son las siguientes:

$$PC_g = \frac{\|ExG\|}{\|ExR\| + \|ExG\| + \|ExB\|} \quad (44)$$

$$PC_r = \frac{\|ExR\|}{\|ExR\| + \|ExG\| + \|ExB\|} \quad (45)$$

$$PC_b = \frac{\|ExB\|}{\|ExR\| + \|ExG\| + \|ExB\|} \quad (46)$$

Donde el símbolo $\|\cdot\|$ representa la norma de la matriz dada. Si los umbrales no son alcanzados por los valores dados por PC_g , PC_r o PC_b significa que la imagen no contiene una gran cantidad de información en esas bandas, por lo que no se extraerá la información de la banda para su procesamiento y caracterización en detalle por separado. En el caso de que exista suficiente información en las bandas, se extraen las regiones y se activan las banderas Hay_vegetación/Prop_verdes, Hay_suelo/Prop_rojos y Hay_cielo/Prop_azules, para así poder controlar el procesamiento de la caracterización de las imágenes generadas.



Figura 9. Esquema detallado de la Segmentación por la información de cromaticidad

Es posible que ciertos elementos presentes en las imágenes no caigan dentro de estos elementos, por ejemplo, torretas de transmisión de electricidad, vehículos, puentes o carreteras, entre otros, siendo estos elementos procesados sin ningún procedimiento específico.

Se ha utilizado el método de Otsu (Otsu, 1979) para binarizar las imágenes obtenidas mediante los índices cromáticos, en caso de que se haya determinado una suficiente proporción de información en la banda correspondiente, exceso de verdes binarizada para la extracción de la región de la vegetación, procediendo de similar manera para la identificación y extracción de la región del suelo y cielo, en donde se binarizó la imagen del índice de exceso de rojo y del exceso de azules.

Las imágenes binarizadas son suavizadas mediante la aplicación del filtro de la mediana, aspecto importante de realizar sobre todo en la banda de rojos, donde se observó cierta

presencia de información, combinada con los verdes, en la región donde existe vegetación, por lo que se obtienen pequeños artefactos presentes en las imágenes binarias resultantes, que al aplicar el filtro de la mediana tienden a desaparecer, rescatando de esta manera píxeles que pueden contener información de vegetación y que por tanto no se deberán separar como parte del suelo.

A continuación, las imágenes obtenidas de la extracción de los elementos de vegetación y de suelo son procesadas para su caracterización mediante el algoritmo de redes neuronales de mapas auto-organizados, que como se ha comentado es un algoritmo que puede ser utilizado para la búsqueda y definición de las características que describan por ejemplo los grupos de elementos contenidos en las imágenes. En esta fase el algoritmo es ejecutado de manera iterativa para caracterizar el cultivo, el suelo y por supuesto el resto de la imagen que puede incluir la región de cielo.

4. Capítulo 4. Análisis de resultados

4.1 Introducción

Establecidos los caminos seguidos para el desarrollo de la solución del problema planteado en la investigación, en este capítulo se realiza la valoración de los resultados obtenidos.

El objetivo principal del trabajo, como ya se ha mencionado, es la identificación automática de texturas en campos de cultivo, más concretamente la identificación de la parte vegetal y la parte del suelo, luego de lo cual cada una de estas partes se vuelve a procesar para reclasificar su contenido y encontrar otras posibles estructuras de textura que estén presentes.

Como se comentó previamente, este trabajo de investigación se ha desarrollado en dos fases claramente diferenciadas.

Una primera fase en la que se han probado algunos de los principales algoritmos de manera directa, sobre un determinado número de imágenes reales y en los que en general, no se han podido clasificar inicialmente de forma automática las imágenes de un campo de cultivo, ya que no fue posible encontrar el mejor número de clases posibles para las imágenes dadas, mediante el uso de índices de validación de clústeres, y de las que no se conoce de antemano el número de clases existentes en ellas. Seguidamente, como una variante al proceso planteado a esta primera fase, se ha logrado determinar el número de clases contenidas en una imagen dada, mediante el cálculo del error cuadrático medio, que ha sido utilizado para medir la calidad de la imagen construida a partir de las características aprendidas por los algoritmos, quedándonos con la agrupación que produce el menor error posible.

Los pasos seguidos para alcanzar este objetivo han sido los que se exponen a continuación, utilizando primeramente unas bases de datos de pruebas que son descritas en la sección 4.2 para luego utilizar las imágenes nuevas a clasificar obteniendo los resultados de la sección 4.3

- Probar índices de validación de particiones internos, con conjuntos de datos públicos, procedentes del repositorio UCI, *Learning Machine Repository*, para por un lado comprobar los resultados referentes a la naturaleza topológica de los datos, seleccionar una batería de índices de validación y con esta información tratar de automatizar los algoritmos de clasificación. Los resultados fueron parcialmente verificados, en unos casos resultando tal como se describe en el repositorio, pero en otros no, posteriormente se proporcionan datos relativos a este aspecto.
- Luego de esto, probar con imágenes reales procurando controlar los resultados a partir de los índices de validación. Los resultados en este caso fueron negativos, por no

poder determinar de manera concluyente el número de agrupaciones en las imágenes utilizadas, motivo por el cual se decide entrar en una segunda fase, cambiando la estrategia inicialmente planteada y buscando otra forma sobre cómo solucionar el problema.

En la segunda fase, los resultados que se han obtenido son más consistentes, por lo que en alguna medida se considera que se aporta en la temática de este trabajo de investigación. En principio nos centramos en los trabajos que utilizan imágenes de cultivos y tenemos en cuenta que nuestras imágenes están representadas en el espacio de color RGB. Los pasos seguidos aquí son los explicados en las secciones 3.2 y 3.3, aplicados en imágenes reales del conjunto de imágenes descritas en la sección 4.4 y con los resultados de la sección 4.5.

4.2 Descripción de las bases de datos utilizadas

Se dispone de un conjunto de bases de datos descargadas de la web durante el mes de noviembre de 2016 procedente del repositorio UCI, *Learning Machine Repository*. Se trata de bases de datos numéricas cuya dimensión varía en función del número de atributos que presente cada conjunto de muestras y que cada una contiene un atributo con la etiqueta real y que se usa como variable de clase para la verificación de resultados. En la tabla 2 se describen sus principales características en conjunto.

Tabla 2. Dataset desde el Repositorio UCI Repository y sus principales características

Dataset	Num. Clústeres	Tipo de Dato	Num. atributos	Num. Instancias
<i>Iris</i>	3	Numérico	4	150
<i>Wine</i>	3	Numérico	13	178
<i>Ecoli</i>	8	Numérico	7	336
<i>Glass</i>	6	Numérico	9	214
<i>Wine Quality</i>	11	Numérico	12	4896

4.3 Elección de los índices de validación de clústeres

De conformidad a lo expresado en las secciones 2.6, 3.2.1.2 y 3.2.6, para este estudio se sigue la propuesta establecida en (Sevilla y col., 2016) para la evaluación de los resultados obtenidos en los distintos algoritmos utilizados en agrupamientos *crisp*. Así, se establece que la topología de las clases contenidas en una colección de datos puede ser entendida mediante el cálculo del siguiente conjunto de índices de validación de agrupaciones: Diámetro (Δ), Separación (δ), Calinski-Harabasz (CH), Dunn (D) y Entropía (E).

En lo referente al algoritmo de clasificación *fuzzy clustering*, existen diferentes medidas escalares para validar la partición obtenida, siendo el objetivo encontrar el número de

clústeres que obtenga las mejores medidas. En este caso se consideran los siguientes coeficientes e índices (Pajares y Cruz, 2011): el Coeficiente de Partición (CP), el Coeficiente de Entropía (CE), el Índice de Partición (SC), el Índice de Separación (S) y el Índice de Dunn (DI).

4.4 Base de imágenes para el estudio

Se ha utilizado principalmente un conjunto de noventa y dos imágenes digitales de campos reales de cultivos de maíz y de cebada, tomadas en un campo experimental en “La Estación de Investigación de Poveda”, Arganda del Rey, Madrid, entre los meses de abril y mayo de 2007. Las imágenes digitales proporcionadas en formato “JPG” tienen un tamaño de 800 x 600 píxeles, capturando imágenes en el espacio de color RGB, con una cámara digital, HPR817.

Como parte de los datos para la evaluación de los resultados se incluyen también un conjunto de ochenta imágenes obtenidas de los campos del Ecuador, de la zona agrícola de Balzar y El Empalme, tomadas desde la cámara de un celular Samsung s7 Edge, las cuales fueron pre procesadas para que queden del tamaño de las otras imágenes utilizadas en este estudio, esto es de 800 x 600 píxeles.

Lo que hace un total de 172 imágenes a ser consideradas para la realización de este trabajo de investigación.

4.5 Resultados obtenidos del método propuesto y estudio comparativo

La primera parte de la investigación proporciona dos resultados muy concretos, el primero es que la ejecución iterativa y directamente de todos los algoritmos sobre las imágenes dadas, proyecta resultados aceptables para el contexto. Basta con indicar que todos los algoritmos generaron respuestas en todas las iteraciones realizadas.

Segundo, la utilización de los índices de calidad como soporte para la toma de decisión referente al número de agrupaciones presentes en la imagen de entrada, resulta complicada por la dispersión evidenciada en los resultados del número de agrupaciones obtenidas.

Tabla 3. Resumen estadístico de la ejecución de la investigación

Algoritmo	Estadísticas - CVI elegidos			Estadísticas – Otros CVI		
	Media	Mediana	Desv. Std	Media	Mediana	Desv. Std
<i>Fuzzy Clustering</i>	8	8	7	9	9	7
<i>K-means</i>	7	6	2	9	10	1
LVQ	13	4	13	23	13	12
<i>Mean Shift</i>	27	5	31	53	21	15
SOM	6	4	1	9	9	1
SOM+IC	11	10	1	12	13	1

Como se observa a partir de la tabla 3, la dispersión es para el contexto relativamente grande en ambos conjuntos de indicadores de calidad de las agrupaciones, estos es, los indicadores elegidos y el otro conjunto de indicadores, siendo no obstante, menor para el método propuesto y para el conjunto de indicadores de calidad elegidos.

Ante esto, se replantea el proceso para tratar las imágenes de entrada como una señal de entrada, que se desea reconstruir y por tanto, se intenta con éxito una reconstrucción basada en los descriptores encontrados por cada uno de los algoritmos y guiando la toma de decisión con dos indicadores de calidad de reconstrucción de señales clásicos, como son el error cuadrático medio y la PSNR.

Considerando sólo los indicadores del error cuadrático medio, la variación disminuye en este caso representativo del conjunto de imágenes, por lo que habría que seguir indagando en el futuro para determinar si este comportamiento es susceptible de generalizar.

Tabla 4. Resumen de los promedios de los indicadores MSE

Algoritmo	Promedio de MSE	
	Conjunto de entrenamiento	Conjunto de prueba
<i>Fuzzy clustering</i>	18.5225	42.9367
<i>K-means</i>	16.6886	32.2598
LVQ	4.8137	11.5893
<i>Mean Shift</i>	5.2354	12.9693
SOM	25.0314	54.5198
SOM+IC	27.3523	40.5366

A partir de la observación de los resultados de las tablas 3 y 4, se puede observar en todos los casos una disminución importante de la dispersión o variación en referencia a la variable del número de agrupaciones presentes en la imagen, por lo que el método se puede considerar para su aplicación. Por otro lado también se puede ver una disminución en los errores de reconstrucción de las imágenes a partir de los valores de MSE.

4.5.1 Estudio detallado de casos

En general el proceso seguido es el siguiente, primero, generar los datos de las matrices de datos con información de cromaticidad de la imagen de entrada, a continuación calcular la proporción presente de información de estas bandas de color en la imagen a analizar, tomando en cuenta los valores de umbrales establecidos por experimentación, luego realizar la binarización de las imágenes de índices de cromaticidad, aplicando el método de Otsu, extraer las porciones correspondientes desde la imagen de entrada, caracterizar cada una de

las imágenes segmentadas por cromaticidad con el algoritmo SOM, seleccionar las mejores características mediante la elección del mejor grupo por votación de los indicadores CVI y almacenamiento de las características encontradas.

En lo que tiene que ver con la elección del mejor grupo la manera de proceder es la siguiente, se calcula cada uno de los indicadores de validación de clústeres, según sea el caso, del algoritmo *fuzzy* o los demás algoritmos de naturaleza *crisp*. Luego para cada una de las particiones generadas y de acuerdo con el criterio correspondiente, se le da un voto a la partición que cumple el criterio, por ejemplo, para ambos tipos de agrupaciones, el indicador coeficiente de entropía privilegia la partición que dé el menor valor de este indicador y por tanto a la partición que tenga el menor valor de este indicador de validación tendrá un voto para este caso, dejando con cero votos para el resto de las particiones. En las agrupaciones *crisp*, para el caso del indicador Diámetro máximo del grupo (Δ) también privilegia la partición que dé el menor valor de este indicador y por tanto a la partición que tenga el menor valor de este indicador de validación tendrá un voto para este caso, dejando con cero votos para el resto de las particiones y así con el resto de los indicadores. Luego de verificado los criterios para cada indicador de validación se procede con la suma de votos, eligiendo la partición que más votos ha recibido, en caso de empate se establece como regla, elegir la partición con más características encontradas.

Cabe indicar que para el método propuesto este proceso se realiza para cada una de las imágenes generadas por segmentación por cromaticidad, esto es tres veces una por cada canal de color.

4.5.1.1 Muestra 1: 05020089.jpg

En esta sección se describe el proceso realizado en la experimentación con imágenes específicas, como la que se muestra en la figura 10, se ha seleccionado esta imagen por contener información relevante y no relevante, en este caso, vegetación, suelo y cielo como información relevante y otras estructuras como información no relevante. Esta imagen constituye un ejemplo representativo del conjunto de 40 imágenes del conjunto de entrenamiento del total de 92 imágenes de los campos de España disponibles para el análisis.



Figura 10. Muestra 1: Imagen de estudio "05020089.jpg" en espacio RGB

Lo que hacemos en primer lugar es generar los datos de las matrices de datos con información de cromaticidad de la imagen de entrada, como se muestra en la figura 11.




Figura 11. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 1

Simultáneamente, se calcula la proporción presente de información de estas bandas de color en la imagen a analizar, tomando en cuenta los valores de umbrales establecidos por experimentación, con lo cual, desde el punto de vista de la implementación, se activan las banderas Hay_vegetación/Prop_verdes, Hay_suelo/Prop_rojos y Hay_cielo/Prop_azules y controlar el procesamiento de la caracterización.

Si hay suficiente información en las bandas se procede con el siguiente punto que es la binarización de las imágenes de índices de cromaticidad, aplicando el método de Otsu, que para el caso de la imagen de entrada dada los resultados son mostrados en la figura 12.




Figura 12. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c) de la muestra 1

Con las regiones o secciones de interés o no interés identificados se extraen las porciones correspondientes desde la imagen de entrada, tal como se muestra en la figura 13, de manera específica se muestra la información extraída de la vegetación y del suelo en las partes (a) y (b) respectivamente.




Figura 13. Imágenes segmentadas por índices de cromaticidad de la muestra 1, con las estructuras vegetales en (a) y el suelo en (b)

Estas imágenes son procesadas de forma separada con el algoritmo SOM, haciendo que el algoritmo trabaje con datos más uniformes, esto es, reduciendo la variabilidad propia de la imagen inicial por contener ésta, información de más agrupaciones o estructuras a ser detectadas. Los datos de partida para el algoritmo SOM son, números de épocas de 300, ancho de la vecindad o zona de influencia inicial 0.1, factor de disminución de la zona de influencia 0.01.

Los centros característicos encontrados para cada una de las regiones de la imagen de entrada son evaluados mediante los índices de validación de clústeres *crisp*, según se describe en la sección 3.2.6. Cabe indicar que la decisión sobre el número de grupos finalmente seleccionados se realiza por votación, con mayoría simple. En este punto es importante mencionar que la variabilidad observada en los índices de validación de clústeres, en lo referente a la guía de la toma de decisión sobre el número de grupos óptimos a elegir, cuando

se ejecutan los algoritmos con la imagen de entrada sin la separación de regiones, se ve disminuida, logrando de esta manera mejorar la precisión de la determinación del número de grupos a considerar en la mayoría de los índices considerados.

Finalmente, lo que queda es la selección final de los centros característicos elegidos, para lo que realizamos primero la eliminación del centro RGB = (0, 0, 0) en todos los grupos de centros obtenidos y que es generado por la definición de una “región negra” resultante de la aplicación del algoritmo de extracción de la región de interés o no interés, como se ve en la figura 13.

Para la imagen de entrenamiento dada, el algoritmo encontró 18 centros, de los cuales 9 centros característicos corresponden a vegetación, 4 centros característicos corresponden a suelo, 3 centros corresponden a cielo y 2 centros característicos corresponde a elementos de no interés.

La imagen original, al 10% de su tamaño original, y la imagen aprendida reconstruida a partir de la recodificación de los píxeles de la imagen original a su centro más cercano se muestran en las figuras 14 y 15, respectivamente.



Figura 14. Imagen de la muestra 1, redimensionada al 10 por ciento de la imagen original en espacio RGB



Figura 15. Imagen de la muestra 1, reconstruida a partir de 18 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad

El proceso termina guardando los datos de los centros característicos en la base de aprendizaje que será utilizada para realizar la clasificación de otras imágenes digitales, capturadas en otros procesos y/o momentos conteniendo información similar, de forma tal que pueda ser posible su caracterización.

4.5.1.2 Muestra 2: 05020056.jpg

En esta sección se describe el proceso realizado en la experimentación con otra imagen específica, como la que se muestra en la figura 16, se ha seleccionado esta imagen por

contener información relevante y no relevante, en este caso, vegetación y suelo como información relevante, mientras que la porción mínima del cielo en la imagen y otras estructuras se tendrán como información no relevante. Ésta, como en el caso anterior, es otra imagen representativa del conjunto de 40 imágenes digitales asignadas al conjunto de entrenamiento.



Figura 16. Muestra 2: Imagen de estudio "05020056.jpg" en espacio RGB

Como con la muestra 1, lo que hacemos en primer lugar es generar los datos de las matrices con la información de cromaticidad de la imagen de entrada, como se muestra en la figura 17.




Figura 17. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 2

En este punto se debe recalcar que al no existir "suficiente información" en la banda de azules porque la región de cielo en la imagen es relativamente pequeña, la imagen del índice cromático de exceso de azules no señala ninguna información, lo cual se muestra en la imagen del índice cromático por la ausencia de regiones blancas o grises. Los porcentajes exactos de las proporciones de vegetación y suelo son respectivamente treinta y seis y sesenta y cuatro por ciento en este caso.

Como hay suficiente información en las bandas de verdes y rojos, se procede con el siguiente punto que es la binarización de las imágenes de índices de cromaticidad, como se indicó aplicando el método de Otsu, que para el caso de la imagen de entrada dada los resultados son mostrados en la figura 18.



Figura 18. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a) y Exceso de Rojo (ExR) en (b) de la muestra 2

Con las regiones o secciones de interés o no interés identificadas se extraen las porciones correspondientes desde la imagen de entrada, tal como se muestra en la figura 19, de manera específica se muestra la información extraída de la vegetación y del suelo en las partes (a) y (b) respectivamente.




Figura 19. Imágenes segmentadas por índices de cromaticidad de la muestra 2, con las estructuras vegetales en (a) y el suelo en (b)

Estas imágenes al igual que para la muestra 1, son procesadas de forma independiente con el algoritmo SOM, haciendo nuevamente que el algoritmo trabaje con datos más uniformes, reduciendo la variabilidad propia de la imagen inicial por contener esta información de más agrupaciones o estructuras a ser detectadas. Los datos de partida para el algoritmo de las redes neuronales SOM son los mismos que los utilizados en la muestra 1, esto es, número de épocas de 300, ancho de la vecindad o zona de influencia inicial 0.1, factor de disminución de la zona de influencia 0.01.

Finalmente, lo que queda es la selección final de los centros característicos elegidos, para lo que realizamos primero la eliminación del centro RGB = (0, 0, 0) en todos los grupos de centros obtenidos y que es generado por la definición de una “región negra” resultante de la aplicación del algoritmo de extracción de la región de interés o no interés, como se vio en la figura 19.

Para la imagen de entrenamiento dada, el algoritmo encontró 15 centros, de los cuales 5 centros característicos corresponden a vegetación, 5 centros característicos corresponden a suelo y 5 centros característicos corresponde a elementos de no interés.

La imagen original al diez por ciento de su tamaño original, y la imagen aprendida reconstruida a partir de la recodificación de los píxeles de la imagen original a su centro más cercano se muestran en las figura 20 y figura 21, respectivamente.



Figura 20. Imagen de la muestra 2, redimensionada al 10 por ciento de la imagen original en espacio RGB




Figura 21. Imagen de la muestra 2, reconstruida a partir de 15 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad

4.5.1.3 Muestra 3: 05020026.jpg

En esta sección se describe el proceso realizado en la experimentación con un tercer tipo de imágenes específicas, como la que se muestra en la figura 22. Como en los casos anteriores, se ha seleccionado esta imagen por contener información relevante y no relevante, en este caso, vegetación y suelo como información relevante, mientras que en este caso no hay región del cielo en la imagen ni otras estructuras que se tengan como información no relevante.



Figura 22. Muestra 3: Imagen de estudio "05020026.jpg" en espacio RGB

Como en el caso de las muestras 1 y 2, lo que se hace en primer lugar es generar los datos de las matrices con información de cromaticidad de la imagen de entrada, como se muestra en la figura 23.




Figura 23. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 3

En este punto se debe recalcar que al no existir "información" en la banda de azules dado que la región de cielo en la imagen es nula, la imagen del índice cromático de exceso de azules no proporciona ninguna información, lo cual se muestra en los resultados obtenidos por aplicación del ExB por la ausencia de regiones blancas o grises. Los porcentajes obtenidos de las proporciones de vegetación y suelo en esta muestra son respectivamente 39% y 61%.

Si existe suficiente información en las bandas se procede con el siguiente punto consistente en la binarización de las imágenes de índices de cromaticidad, aplicando el método de Otsu, para el caso de la imagen de entrada dada los resultados son mostrados en la figura 24.

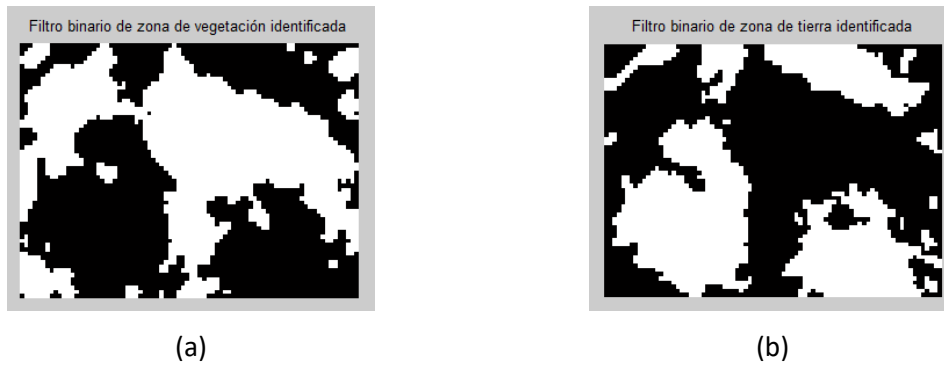


Figura 24. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a) y Exceso de Rojo (ExR) en (b) de la muestra 3

Con las regiones o secciones de interés o no interés identificados se extrae las porciones correspondientes desde la imagen de entrada, tal como se muestra en la figura 25, de manera específica se muestra la información extraída de la vegetación y del suelo en las partes (a) y (b) respectivamente.




Figura 25. Imágenes segmentadas por índices de cromaticidad de la muestra 3, con las estructuras vegetales en (a) y el suelo en (b)

Estas imágenes al igual que para las muestras 1 y 2, se procesan de forma independiente mediante SOM, haciendo que el algoritmo trabaje con datos más uniformes, reduciendo la variabilidad inicial de la imagen inicial por contener esta información de más agrupaciones o estructuras a ser detectadas. Los datos de partida para el algoritmo de las redes neuronales SOM son los mismos que los utilizados en la muestra 1, esto es, número de épocas de 300, ancho de la vecindad o zona de influencia inicial 0.1, factor de disminución de la zona de influencia 0.01.

Finalmente, lo que queda es la selección final de los centros característicos elegidos, para lo que realizamos primero la eliminación del centro RGB = (0, 0, 0) en todos los grupos de centros obtenidos y que es generado por la definición de una “región negra” resultante de la aplicación del algoritmo de extracción de la región de interés o no interés, como se vio en la figura 25.

Para la imagen de entrenamiento dada, el algoritmo encontró 17 centros, de los cuales 10 centros característicos corresponden a vegetación, 7 centros característicos corresponden a suelo y 0 centros característicos corresponde a elementos de no interés.

La imagen original al diez por ciento de su tamaño original, y la imagen aprendida reconstruida a partir de la recodificación de los píxeles de la imagen original a su centro más cercano se muestra en las figura 26 y figura 27, respectivamente.



Figura 26. Imagen de la muestra 3, redimensionada al 10 por ciento de la imagen original en espacio RGB



Figura 27. Imagen de la muestra 3, reconstruida a partir de 17 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad

4.5.1.4 Muestra 4: 05020068.jpg

En esta sección se describe el proceso realizado con otra imagen específica, la que se muestra en la figura 28, del que en el Anexo se presenta más detalle de los resultados obtenidos.



Figura 28. Muestra 4: Imagen de estudio "05020068.jpg" en espacio RGB

Lo que hacemos en primer lugar es generar los datos de las matrices de datos con información de cromaticidad de la imagen de entrada, como se muestra en la figura 29.



(a)

(b)

(c)

Figura 29. Imágenes correspondientes a los índices cromáticos Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c), de la imagen mostrada de la muestra 4

Se calcula la proporción presente de información de estas bandas de color en la imagen a analizar, tomando en cuenta los valores de umbrales establecidos por experimentación, con lo cual y se activan las banderas para controlar el procesamiento de la caracterización, se procede con el la binarización de las imágenes de índices de cromaticidad, aplicando el método de Otsu, que para el caso de la imagen de entrada dada, los resultados son mostrados en la figura 30.



(a)

(b)

(c)

Figura 30. Imágenes conteniendo filtros binarios generados por el método de Otsu de las imágenes de los índices Exceso de Verde (ExG) en (a), Exceso de Rojo (ExR) en (b) y Exceso de Azul (ExB) en (c) de la muestra 4

Se extrae las porciones correspondientes desde la imagen de entrada, tal como se muestra en la figura 31, de manera específica se muestra la información extraída de la vegetación y del suelo en las partes (a) y (b) respectivamente.

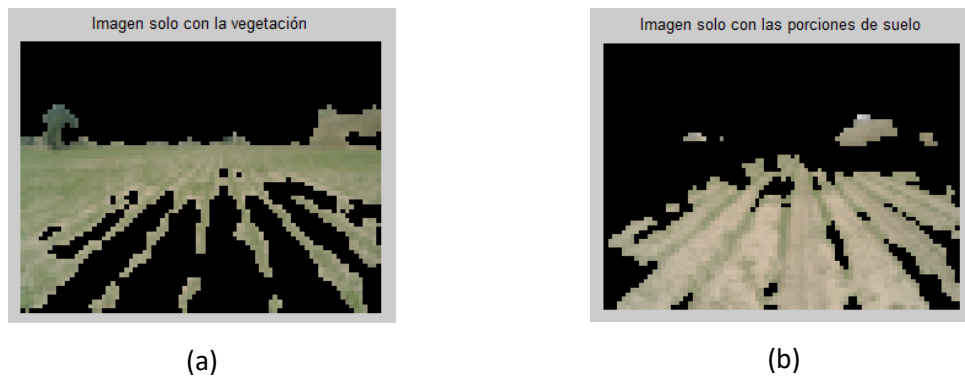


Figura 31. Imágenes segmentadas por índices de cromaticidad de la muestra 4, con las estructuras vegetales en (a) y el suelo en (b)

Estas imágenes son procesadas de forma separada con el algoritmo SOM, haciendo que el algoritmo trabaje con datos más uniformes, puesto que sólo se conservan mayoritariamente las estructuras relacionadas a la banda correspondiente, planteándonos el objetivo de su detección. Los datos de partida para el algoritmo SOM son, como en los casos anteriores, número de épocas 300, ancho de la vecindad o zona de influencia inicial 0.1, factor de disminución de la zona de influencia 0.01.

Los centros característicos encontrados para cada una de las regiones de la imagen de entrada son evaluados mediante los índices de validación de clústeres *crisp*, según se describe en la sección 3.2.6. Cabe indicar que la decisión sobre el número de grupos finalmente seleccionados se realiza por votación, con mayoría simple.

Finalmente, lo que queda es la selección final de los centros característicos elegidos, para lo que realizamos primero la eliminación del centro RGB = (0, 0, 0) en todos los grupos de centros obtenidos y que es generado por la definición de una "región negra" resultante de la aplicación del algoritmo de extracción de la región de interés o no interés, como se vio en la figura 31.

Para la imagen de entrenamiento dada, el algoritmo encontró 12 centros, de los cuales 6 centros característicos corresponden a vegetación, 3 centros característicos corresponden a suelo, 3 centros corresponden a cielo u otros elementos de no interés.

La imagen original al diez por ciento de su tamaño original, y la imagen aprendida reconstruida a partir de la recodificación de los píxeles de la imagen original a su centro más cercano se muestra en las figura 32 y figura 33, respectivamente.



Figura 32. Imagen de la muestra 4, redimensionada al 10 por ciento de la imagen original en espacio RGB



Figura 33. Imagen de la muestra 4, reconstruida a partir de 12 centros aprendidos por el algoritmo SOM de la imagen segmentada por cromaticidad

El proceso termina guardando los datos de los centros característicos en la base de aprendizaje que será utilizada para realizar la clasificación de otras imágenes digitales, capturadas en otros procesos y/o momentos conteniendo información similar, de forma tal que pueda ser posible su caracterización.

4.5.2 Comparación de Resultados

Los resultados están referenciados para el estudio de todos los algoritmos sobre el conjunto de 40 imágenes del conjunto de entrenamiento, los resultados obtenidos en la ejecución de todos los algoritmos sobre el conjunto de imágenes mencionado, se pone a prueba con un conjunto de 12 imágenes distintas, elegidas al azar de las 52 imágenes restantes del conjunto inicialmente disponible más las 80 imágenes de los cultivos de la zona rural de la costa del Ecuador y de las cuales también se derivan los indicadores para efecto de comparación. Los resultados por tanto se asume se refieren al análisis de las 172 imágenes descritas en la sección 4.4.

4.5.2.1 Indicadores de calidad de las agrupaciones

La tabla 5 muestra los resultados de los diferentes CVI para los algoritmos indicados, junto con las agrupaciones sugeridas de conformidad a las reglas definidas para el índice de calidad de agrupación definido. Estos resultados evidencian la disparidad a la hora de definir el número de grupos, se puede comprobar las diferencias importantes entre el indicador del coeficiente de entropía y el de la separación de clúster mínima. Se debe indicar que en general los valores dados por los diferentes índices varían notablemente.

Tabla 5. Agrupaciones sugeridas, reglas para cada CVI seleccionado

Algoritmo	CVI				
	CE	δ	Δ	DI	CH
<i>K-means</i>	2	5	12	6	9
LVQ	2	3	37	8	14
<i>Mean Shift</i>	4	8	78	14	31
SOM	2	5	14	6	5
SOM+IC	6	13	15	11	8
Regla	Mín.	Máx.	Mín.	Máx.	Máx.

Por otra parte, a pesar de la disparidad ya evidenciada, se ha analizado el comportamiento de los otros indicadores de calidad y determinar su respuesta al número de grupos sugeridos, lo que se muestra en la tabla 6, en ella se puede observar cierta paridad entre los índices W y WSS, correspondiente a la distancia media dentro del grupo y a la suma de los cuadrados de las distancias media dentro del grupo y el índice de Xie-Beni, pero diferenciando notablemente con el valor deducido desde el índice de Davies-Bouldin.

Tabla 6. Agrupaciones sugeridas, reglas para otros CVI

Algoritmo	Otros CVI			
	W	WSS	DB	XB
<i>K-means</i>	13	14	4	7
LVQ	36	37	14	7
<i>Mean Shift</i>	64	80	49	20
SOM	13	15	4	6
SOM+IC	15	15	8	11
Regla	Mín.	Mín.	Mín.	Mín.

Finalmente, los datos de la decisión sobre el número de agrupaciones definidas a partir de los indicadores del error cuadrático medio (MSE) y de la relación señal-ruido pico, se muestran en la tabla 7:

Tabla 7. Agrupaciones sugeridas, reglas del MSE y PSNR

Algoritmo	Indicador	
	MSE	PSNR
<i>K-means</i>	14	14
LVQ	19	19
<i>Mean Shift</i>	48	48
SOM	13	12
SOM+IC	17	17
Regla	Mín.	Máx.

Cabe indicar que estos indicadores se perfilan más parecidos al segundo grupo de indicadores de calidad de agrupación, esto es, a los mostrados en la tabla 6.

4.5.2.2 Tiempos de ejecución de los algoritmos

El resumen de las estadísticas del tiempo de ejecución promedio por iteración de los distintos algoritmos probados se muestra en la tabla 8. Se puede observar las diferencias significativas existentes entre los tiempos que demandan las redes SOM, como en el método propuesto y los demás algoritmos, llegando a ser alrededor de 400 veces el mejor tiempo que es dado por el algoritmo de *Mean Shift* o 95 veces el tiempo del algoritmo de *fuzzy clustering*.

Tabla 8. Resumen estadístico Tiempos promedios (segundos) por iteración y por algoritmo

Estadístico	Algoritmo					
	<i>Fuzzy Clustering</i>	<i>K-means</i>	LVQ	<i>Mean Shift</i>	SOM	SOM_IC
Promedio	0.0274	0.0102	0.0213	0.0067	1.7557	2.6048
Mediana	0.0231	0.0102	0.0127	0.0054	1.7538	2.5046
Máximo	0.0649	0.0176	0.0922	0.0169	2.7949	3.7947
Mínimo	0.0023	0.0027	0.0089	0.0047	0.7225	1.7366
Desv. Est.	0.0212	0.0048	0.0222	0.0031	0.6589	0.5933

A continuación, para una mejor comprensión de los tiempos de ejecución de los distintos algoritmos, se muestran en la figura 34 los tiempos de ejecución promedios por iteración y por algoritmos, se puede apreciar claramente que los algoritmos basados en las redes SOM, tienen una proporción de tiempo mucho mayor que los otros algoritmos, también se puede apreciar para el método propuesto como al inicio de las iteraciones debido a que el proceso de búsqueda de características se realiza para tres imágenes, a saber para cada uno de los tres espacios definido por los índices cromáticos, el tiempo se triplica esto es así, hasta la iteración nueve, donde los tiempos prácticamente se igualan con el algoritmo SOM ejecutado directamente sobre la imagen original.




Figura 34. Tiempo de ejecución para la extracción de características de los principales algoritmos

Por tanto, a partir de estos datos, un punto en contra del método propuesto resulta ser la alta demanda de recursos computacionales que requiere, pero que no fue establecido como restricción en la investigación, y que sin embargo para muchas aplicaciones puede resultar un problema difícil de llevar a la práctica. En este aspecto el orden de magnitud del tiempo de ejecución requerido es por lo menos de 100 veces mayor en el algoritmo propuesto.

4.5.2.3 Errores de reconstrucción final

Los errores de reconstrucción son detallados de acuerdo con los criterios expuestos en la sección 3.1 del menor valor de MSE obtenido de las agrupaciones generadas en las iteraciones de los algoritmos ejecutados y de los descriptores obtenidos por el criterio del voto mayoritario de los CVI en los algoritmos ejecutados, tanto para el conjunto de entrenamiento como para el conjunto de pruebas.

Para los descriptores seleccionados por el criterio del menor error cuadrático medio, MSE alcanzado en cada una de las iteraciones de los algoritmos ejecutados sobre el conjunto de las imágenes de entrenamiento, la figura 35 muestra los principales estadísticos de MSE, obtenidos de la imagen original y la imagen codificada desde los descriptores logrados por el criterio en los algoritmos ejecutados. Se puede ver que los mejores rendimientos en este indicador son alcanzados por los algoritmos LVQ y *Mean Shift*, evidenciándose también de igual manera, rendimientos menores y similares entre sí, para los otros tres algoritmos *fuzzy clustering*, *K-means* y SOM. Comportamiento similar se puede comprobar con respecto a los valores obtenidos de la desviación estándar del indicador MSE de las imágenes derivadas de las agrupaciones obtenidas y las imágenes originales, obteniéndose menores valores para los algoritmos LVQ y *Mean Shift*.




Figura 35. Principales estadísticas conjunto de entrenamiento: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del menor MSE alcanzado en los algoritmos ejecutados

Por otra parte, para el conjunto de imágenes de prueba, la figura 36 muestra los principales estadísticos del indicador MSE, obtenidos del procesamiento de la imagen de entrada para la segmentación con cada una de las bases de características generadas desde el conjunto de entrenamiento. Se puede verificar comportamientos similares como los evidenciados para el conjunto de entrenamiento, pero en general con valores superiores, lo que denota una disminución de la precisión de la identificación de los descriptores en las imágenes probadas.




Figura 36. Principales estadísticas conjunto de prueba: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del menor MSE alcanzado en los algoritmos ejecutados

Para los descriptores seleccionados por el criterio del voto mayoritario de los CVI de las agrupaciones generadas en los algoritmos ejecutados, en la figura 37 se muestra los estadísticos principales del MSE y se puede apreciar nuevamente los mejores desempeños alcanzados por algoritmos LVQ y Mean Shift, aunque se verifica también que la calidad de la reconstrucción obtenida para la imagen de entrenamiento es menor, por los mayores valores obtenidos en comparación a los centros obtenidos por el criterio previamente explicado.

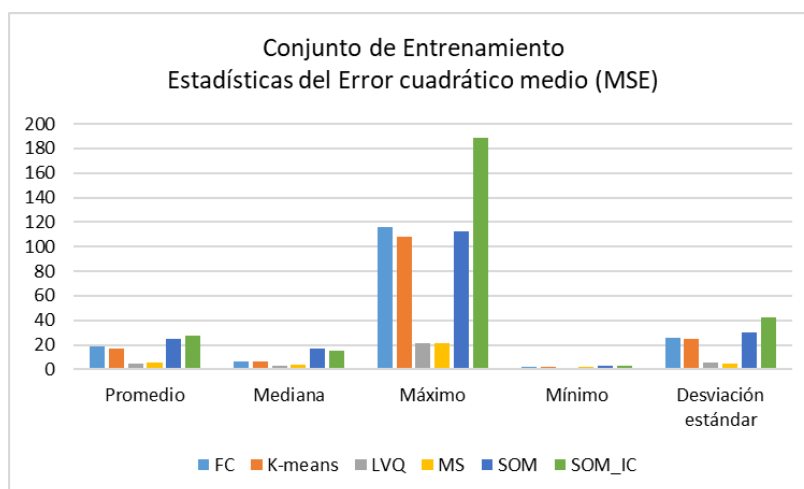


Figura 37. Principales estadísticas conjunto de entrenamiento: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del voto mayoritario de CVI en los algoritmos ejecutados

Similarmente, la figura 38 muestra la concentración de los datos del MSE para cada uno de los algoritmos, para lo cual se hace uso de diagramas de cajas, confirmando en el conjunto de entrenamiento los mejores desempeños de los algoritmos LVQ y *Mean Shift* con las características obtenidas con el criterio del voto mayoritario de los indicadores CVI.

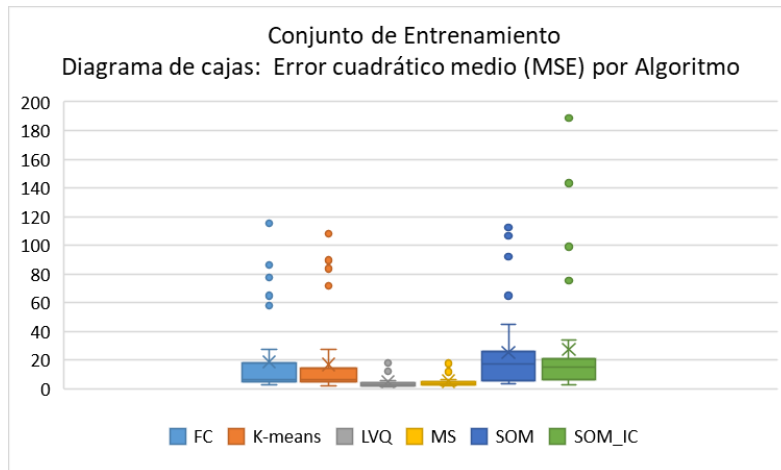


Figura 38. Diagrama de cajas conjunto de entrenamiento: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del voto mayoritario del CVI en los algoritmos ejecutados

La figura 39 muestra las principales estadísticas de los datos del error cuadrático medio para cada uno de los algoritmos, sobre el conjunto de prueba, pero con características obtenidas por el criterio del voto mayoritario de los CVI de los algoritmos ejecutados en las particiones, confirmando los mejores desempeños de los algoritmos LVQ y *Mean Shift* como en el conjunto de entrenamiento, confirmando también los mejores desempeños alcanzados por los algoritmos LVQ y *Mean Shift*, aunque la calidad de la reconstrucción obtenida para la imagen de entrenamiento es menor.




Figura 39. Principales estadísticas conjunto de pruebas: Error cuadrático medio (MSE) por algoritmo. Descriptores obtenidos por el criterio del voto mayoritario del CVI en los algoritmos ejecutados

Finalmente, la figura 40 muestra la concentración de los datos del error cuadrático medio para cada uno de los algoritmos, para lo cual se hace uso de diagramas de cajas, pero con los datos de las imágenes del conjunto de prueba, confirmando los mejores desempeños de los algoritmos LVQ y *Mean Shift* en el conjunto de entrenamiento también con las características obtenidas con el criterio del voto mayoritario de los CVI de los algoritmos ejecutados en las particiones, aunque la calidad de la reconstrucción obtenida para la imagen de prueba es menor.




Figura 40. Principales estadística conjunto de pruebas: Error cuadrático medio (MSE) por algoritmo Descriptores obtenidos por el criterio del voto mayoritario del CVI en los algoritmos ejecutados

4.5.2.4 Ilustración de los resultados

A continuación se muestran los resultados de los procesos de codificación de dos imágenes representativas del conjunto total de imágenes disponibles, una del conjunto de imágenes de los campos en España y otro del conjunto de imágenes de los campos en Ecuador, solo con propósitos de ilustración final de los resultados y que en términos generales es aplicable al conjunto de imágenes analizadas.

Imagen de los campos de España: 05020068.JPG

Esta imagen pertenece al conjunto de entrenamiento y se puede observar a simple vista los menores desempeños de los algoritmos SOM y *Fuzzy Clustering*, especialmente en la porción del cielo de la imagen, de igual manera destaca los mejores resultados obtenidos por el algoritmo de *Mean Shift* y un poco menos el algoritmo LVQ.

La figura 41 muestra las reconstrucciones de la imagen acuerdo con los vectores obtenidos por el criterio de los votos mayoritarios de los CVI de las agrupaciones para cada algoritmo probado de manera directa.



Figura 41. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por votos de los CVI de las agrupaciones.

Mientras que en la figura 42 muestra las reconstrucciones de la imagen de acuerdo con los vectores obtenidos por el criterio del menor MSE de las agrupaciones para cada algoritmo probado de manera directa. Se puede apreciar en este caso, un mejor rendimiento en todos los algoritmos.



Figura 42. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por el menor MSE de agrupación.

En la figura 43 se muestra las reconstrucciones de la imagen de tres ejecuciones del método propuesto con los vectores obtenidos para cada una de estas ejecuciones y de acuerdo con el criterio del voto mayoritario de los CVI de las distintas agrupaciones obtenidas. Se puede apreciar en este caso, un mejor rendimiento en las tres ejecuciones.

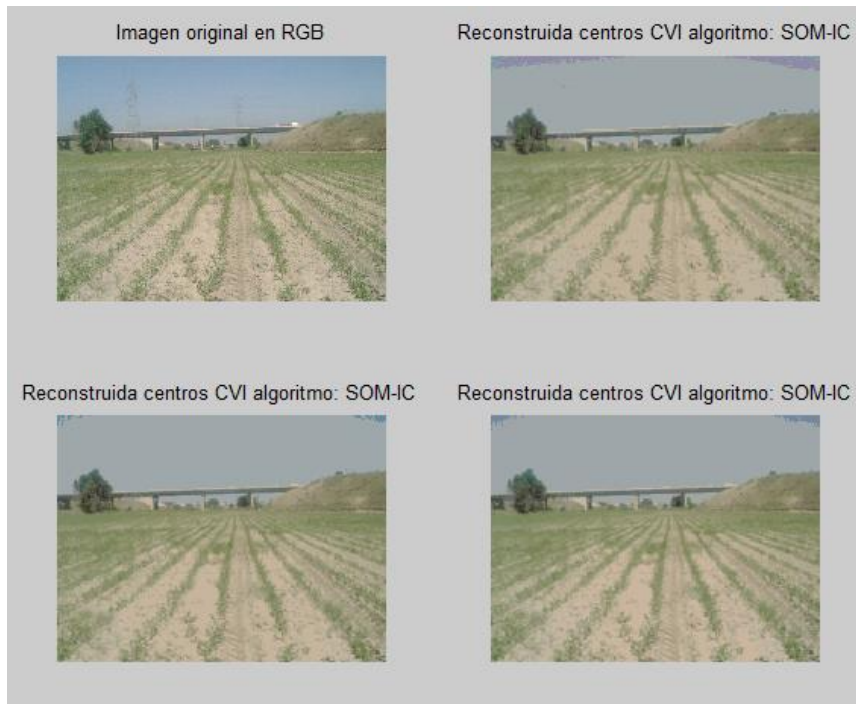


Figura 43. Imagen codificada de acuerdo con los vectores de características detectados en tres ejecuciones del algoritmo propuesto, con la elección de centros por votos de los CVI de las agrupaciones.

Imagen de los campos de Ecuador: 20180404_090421.jpg

De manera similar, las figuras 44, 45 y 46 muestran los resultados para una imagen perteneciente a los campos en Ecuador, representativa de este tipo de imágenes y que se utiliza para la prueba de los resultados.

La imagen 20180404_090421.jpg pertenece al conjunto de prueba y se puede observar en la figura 44 en general los menores desempeños de todos los algoritmos para el caso de los centros elegidos por el criterio del voto mayoritario de los indicadores CVI de las agrupaciones, incluida las generadas por el método propuesto, que se muestran en la figura 46.

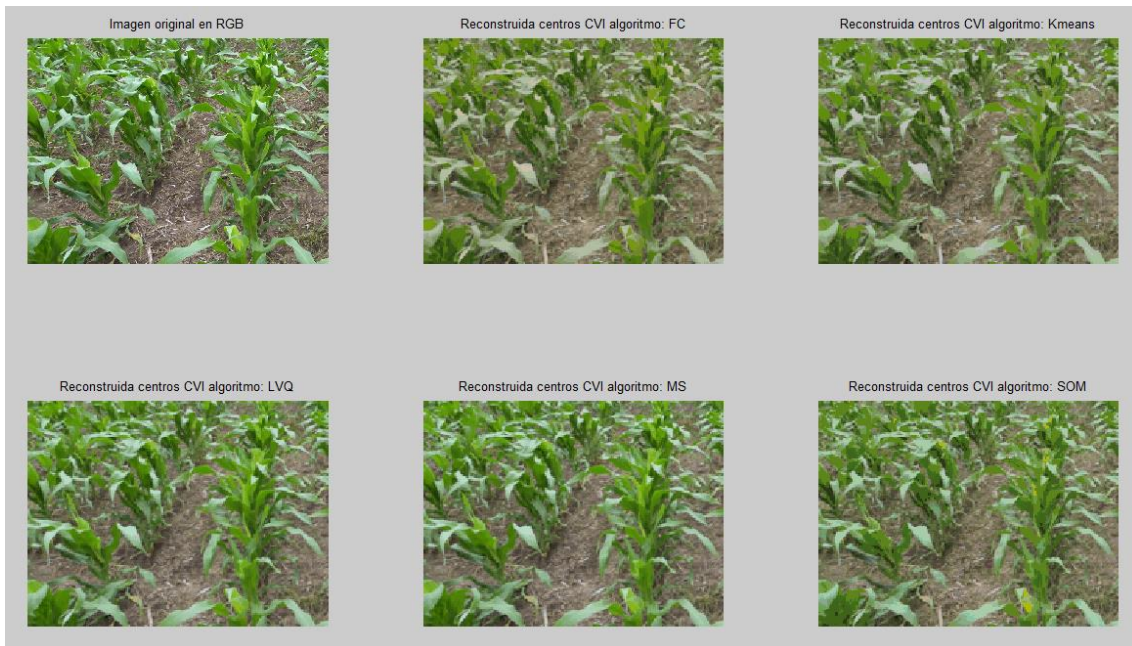


Figura 44. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por votos de los CVI de las agrupaciones.

Destaca la mejor presentación de las imágenes reconstruidas que son obtenidas por los centros elegidos por el criterio de menor MSE para todos los algoritmos, lo que se muestra en las imágenes codificadas en la figura 45.




Figura 45. Imagen codificada de acuerdo con los vectores de características detectados por cada uno de los algoritmos probados, con la elección de centros por el menor MSE de agrupación.

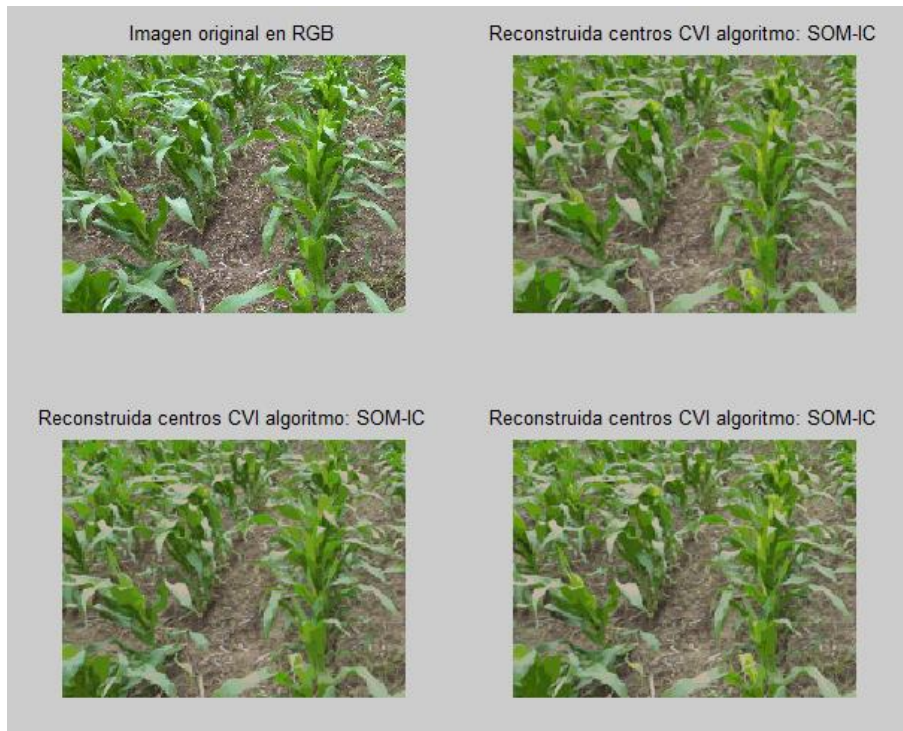


Figura 46. Imagen codificada de acuerdo con los vectores de características detectados en tres ejecuciones del algoritmo propuesto, con la elección de centros por votos de los CVI de las agrupaciones.

5. Capítulo 5. Conclusiones y trabajo futuro

Teniendo en cuenta el trabajo realizado y realizando una síntesis de los resultados obtenidos se llega a las conclusiones que se detallan a continuación:

- Se ha comprobado en los experimentos realizados que todos los métodos probados producen resultados viables de utilizar para la tarea de identificar y clasificar las texturas naturales presentes en las imágenes, tomando en cuenta la información espectral disponible en los datos. En todos los casos es necesario un estudio detallado de los parámetros que los definen y así alcanzar los mejores resultados.
- El uso de indicadores de calidad de las agrupaciones, aplicados directamente sobre los resultados obtenidos de la ejecución directa de los algoritmos de clasificación para tratar de evaluar los resultados obtenidos y decidir sobre el número de agrupaciones presentes, ha resultado complicado de realizar debido a la variabilidad de la respuesta generada por cada indicador. En este sentido de los experimentos realizados, el coeficiente de entropía definitivamente difiere en gran medida de los resultados generados por los otros indicadores, lo que hace necesario un estudio más profundo de esta característica en las imágenes digitales como las estudiadas aquí.
- Una de las causas de la complicación indicada en el punto anterior, puede deberse a la diversidad de estructuras presentes en las imágenes digitales utilizadas en el estudio y que es característico de imágenes agrícolas en ambiente de exteriores. Tampoco se pueden descartar los posibles efectos de los cambios en la iluminación como contribuyente a este problema, esto motivó a tratar de buscar y encontrar, o más bien generar, imágenes más uniformes en su contenido para así tratar de obtener descriptores más precisos de los elementos contenidos en las imágenes generadas y con esto de las imágenes de entrada disponibles.
- La extracción de regiones de las imágenes digitales, por medio de la aplicación de los índices cromáticos, ayuda mucho al proceso de identificación y clasificación de las texturas presentes en la imagen, precisamente por lograr de manera efectiva resolver en buena medida el problema de la no uniformidad inherente de las imágenes procesadas, lo que ayuda a clarificar el problema de detectar texturas diferentes pero de un mismo tipo, para el caso, los posibles distintos tipos de vegetación y distintos tipos de suelos presentes en las imágenes.
- A pesar de que en el presente trabajo sólo se ha realizado un trabajo experimental de prueba y error con un grupo de imágenes determinado, se ha visto una menor variabilidad en las conclusiones sobre el número de agrupaciones presentes en las

imágenes derivadas de la aplicación de los indicadores de calidad de las agrupaciones, con el procedimiento descrito, por lo que es de esperar que realizando un estudio más amplio y exhaustivo al respecto se pueda mejorar la obtención de resultados.

- La elección final y la aplicación del método de clasificación SOM para realizar la caracterización de las estructuras presentes en las imágenes digitales utilizadas, obedece a la necesidad de encontrar una estructura simple y a la vez efectiva que recoja de la mejor manera toda la información disponible en la entrada al proceso de clasificación y las relaciones que existan entre sí, lo cual involucra la información de respuesta espectral, la de ubicación y la de escala de los elementos presentes en la imagen. En este sentido los resultados obtenidos de la aplicación de este método son alentadores, más aún con la propuesta realizada para “facilitar el trabajo”, no obstante de ser necesario un estudio más detallado que permita ver cómo mejorar los tiempos de proceso, demasiado altos, para una extracción “completa” de todos los elementos de interés que se encuentran presentes en la estructura generada.
- Es concluyente también de las pruebas realizadas los excelentes desempeños logrados en la caracterización de las imágenes por los algoritmos *Mean Shift* y LVQ, a la luz de los resultados obtenidos, por lo que su utilización en procesos como el estudiado en el presente trabajo o de combinación de clasificadores se ve altamente viable.
- La aplicación del mecanismo del error cuadrático medio es un medio relativamente económico y efectivo para evaluar la calidad del resultado propuesto por uno u otro de los métodos de clasificación, por lo que su utilización puede ser recomendable para guiar la toma de decisión sobre el número de grupos “realmente” presentes en una imagen dada.

Finalmente, la continuidad de este trabajo se puede orientar en varias líneas que se describen a continuación:

- En primer lugar buscando comprender mejor de manera las relaciones existentes en las imágenes digitales utilizadas, se debe ampliar la utilización a otras estructuras topológicas en las redes SOM, para tratar de evidenciar las posibles relaciones existentes en los datos de las imágenes.
- Otra posible línea de acción es tratar de manera más profunda las características que definen las agrupaciones del tipo de imágenes tratadas, quizás incluyendo de manera simultánea la información de respuesta espectral, ubicación y escala de los elementos en los algoritmos y ver los resultados obtenidos.

- Siendo la medida de distancias uno de los elementos más críticos en el desarrollo de los distintos métodos de clasificación probados, se debe experimentar también la investigación con las distintas alternativas de medida de ésta y ver su influencia en los resultados generados.
- Explorar la combinación de los diversos clasificadores disponibles, tratando sin embargo de no complicar excesivamente el proceso en términos computacionales, además de procurar simultáneamente buscar también establecer un tratamiento efectivo o una combinación simple de toda la información incluida en las imágenes.
- Finalmente, mejorar la medición de la precisión de los algoritmos con la creación de un conjunto de datos *Ground truth* que pueda ser utilizado como referencia y ampliar la generación de resultados a otros tipos de estructuras o sistemas de cultivos, tales como arroz, caña de azúcar, campos de árboles frutales como mango, papaya, entre otros, seguramente mediante la utilización de imágenes digitales generadas a partir de drones o sistemas autónomos, convenientemente preparadas.

6. Referencias Bibliográficas

- Arbelaitz, O., Gurrutxaga, I., Muguerza, J., Pérez, J.M., Perona, I.: An extensive comparative study of cluster validity indices. *Pattern Recognition*. 46(1), 243–256. 2013
- Bezdek, J.C., Pal, N.R.: Some new indexes of cluster validity. *IEEE Trans. Syst. Man Cybern. Part B Cybern.* 28(3), 301–315. 1998
- Bianco, S., Cusano, C., Napoletano, P., Schettini. Improving CNN-Based Texture Classification by Color Balancing. *Journal of Imaging*, 15 pages. 2017
- Brun, M., Sima, C., Hua, J., Lowey, J., Carroll, B., Suh, E., Dougherty, E.R.: Model-based evaluation of clustering validation measures. *Pattern Recognition*. 40(3), 807–824. 2007
- Calinski, T., Harabasz, J. A dendrite method for cluster analysis, *Communications in Statistics*, 3:1, 1-27, 1974
- Cheng Y., Mean Shift, Mode Seeking and Clustering. 1995
- Comaniciu D. y Meer P., Mean Shift: A Robust Approach toward Feature Space Analysis. 2002
- Duda R.O, Hart, P.E. y Stork D.G., *Pattern Classification*. Second Edition. Wiley, New York. 2001
- Duda, R.O., Hart, P.E., Stork, D.G.: *Pattern Classification*. Wiley, Hoboken. 2012
- Dumoulin and Visin. A guide to convolution arithmetic for deep learning. arXiv:1603.07285v1 [stat.ML]. 2016.
- Dunn, J. C. Well separated clusters and optimal fuzzy-partitions. *Journal of Cybernetics*, 4:95–104, 1974
- Fukunaga, K. The Estimation of the Gradient of a Density Function, with Applications in *Pattern Recognition*. 1975
- Gée, Ch., Bossu, J., Jones, G., Truchetet, F., Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture* 60, 49-59. 2008
- Georgiadis G., Chiuso A., Soatto S., “Texture Representations for Image and Video Synthesis”, *IEEE Conference on Computer Vision and Pattern Recognition*, 2015
- Guijarro, M. Combinación de clasificadores para identificación de texturas en imágenes naturales: nuevas estrategias locales y globales. Tesis doctoral. Facultad de Informática. Universidad Complutense de Madrid, 2009
- Guijarro, M. Riomoros, I. Pajares, G. Zitinski, P. Discrete wavelets transform for improving greenness image segmentation in agricultural images. - *Computers and Electronics in Agriculture*, 118, 396 – 407. 2015
- Hartigan J. A., Wong M. A. Algorithm AS 136: A K-Means Clustering Algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* Vol. 28, No. 1, 1979
- Hebb, D.O. *The Organization of Behavior: A Neuropsychological Theory*. Wiley, New York, USA. 1949
- J. R. Parker, *Algorithms for Image Processing and Computer Vision*, Second Edition. Wiley. 2011

- Kohonen, T. Self-Organization and Associative Memory. Springer-Verlag, Berlin. 1984
- Kohonen, T. Self-Organization Map. Proc. of the IEEE, 78(9), 1464-1480. 1990
- Manual de agricultura de precisión / IICA, PROCISUR - Montevideo: IICA, 2014 (accedido agosto 2017)
- Maulik, U., Bandyopadhyay, S.: Performance evaluation of some clustering algorithms and validity indices. IEEE Trans. Pattern Analytic Machine Intelligence 24, 1650–1654. 2002
- Meyer George. E., Machine Vision Identification of Plants. 2011
- Meyer, G.E., Camargo-Neto, J.. Verification of color vegetation indices for automated crop imaging applications. Computers and Electronics in Agriculture 63, 282-293, 2008
- Meyer, G.E., Hindman, T.W., Lakshmi, K., Machine Vision Detection Parameters for Plant Species Identification. SPIE, Bellingham, WA. 1998
- Ministério da Agricultura, Pecuária e Abastecimento, Brasil. Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Agricultura de Precisão. Boletim Técnico. Brasília, Brasil 3a ed. 40 p. 2013. http://www.agricultura.gov.br/arq_editor/Boletim%20tecnico.pdf (accedido agosto 2017)
- Oja, E., Ogawa, H. y Wangviwattana, J., Principal Component Analysis by homogeneous Neural Network, Part II: analysis and extensions of learning algorithms. IEICE Trans. On Information and Systems, E75.D, 3, 376-382. 1992
- Omatu S., Detection of Rice-Area Using Self-Organizing Feature Map. 2015
- Otsu, N. A threshold selection method from gray-level histogram. IEEE Trans. System Man and Cybernetics 9, 62-66. 1979
- Pajares, G. y Cruz, J. Aprendizaje Automático. RA-MA, Ediciones de la U. Bogotá, Colombia. 2011
- Pajares, G. y Cruz, J. Visión por Computador: Imágenes digitales y Aplicaciones. Segunda Edición. RA-MA, Madrid. 2007
- Peña, J.M., Torres-Sánchez, J., Serrano-Pérez, A., López-Granados, F., Detección de malas hierbas en girasol en fase temprana mediante imágenes tomadas con un vehículo aéreo no tripulado (UAV). Revista de Teledetección. 2014
- Pierce y Nowak, 1999, Advances in Agronomy. Aspects of Precision Agriculture, Volume 67 Pages 1-85
- [Population Projections, UN: https://esa.un.org/unpd/wpp/](https://esa.un.org/unpd/wpp/) (2017) (accedido Agosto 2017)
- Ribeiro A., Fernández-Quintanilla C., Barroso J., García-Alegre, M.C. 2005. Development of an image analysis system for estimation of weed. In Proc.5th European Conf. On Precision Agriculture (5ECPA) 169–174
- Riomoros M. I., Segmentación automática de texturas en imágenes agrícolas. Tesis Doctoral. Facultad de Informática. Universidad Complutense de Madrid, 2016
- Sevilla-Villanueva B., Gibert K., Sánchez-Marrè M. Using CVI for Understanding Class Topology in Unsupervised Scenarios. 2016
- Sezgin, M., Sankur, B., Survey over image thresholding techniques and quantitative performance evaluation. J. Electron. Imaging 13 (1), 146–165. 2004

- Shapiro, L.G., Stockman, G.C. Computer Vision. First Edition. Pearson. 2001
- Shrestha, D.S., Steward, B.L., Birrell, S.J. Video processing for early stage maize plant detection. Biosyst. Eng. 89 (2), 119–129, 2004
- Tellaeché, A., Burgos-Artizzu, X. Pajares, G., Ribeiro, A. and Fernández-Quintanilla, C.. A new vision-based approach to differential spraying in precision agriculture. Computers and Electronics in Agriculture, vol. 60(2), 144-155, 2008
- Theodoridis, S., Koutroumbas, K. Pattern Recognition. Fourth Edition. Elsevier, 2009
- Woebbecke, D.M., Meyer, G.E., von Bargen, K. and Mortensen, D.A. Shape features for identifying **young** weeds using image analysis. Trans. Am. Soc. Agric. Eng. 38 (1), 271–281, 1995
- Wackerly, Dennis; Scheaffer, William. *Mathematical Statistics with Applications* (7 edición). Belmont, CA, USA: Thomson Higher Education. 2008
- Yingjie, T.; Qi, Z. Nonparallel Support Vector Machines for Pattern Classification. IEEE Transactions on Cybernetics. 44(7) 1067 – 1079, 2014
- Zheng, L., Zhang, J., Wang, Q. Mean-shift-based color segmentation of images containing green vegetation. Computers and Electronics in Agriculture, 65,93–98. 2009

7. Anexo

A continuación se muestra de manera detallada los gráficos de los valores de los distintos índices de validación de clústeres (CVI, por sus siglas en inglés) calculados para la muestra 4, esto es la imagen 05020068.jpg y resaltando con un punto rojo el mejor número de grupos de la muestra según el criterio establecido para cada índice. Los índices son calculados para cada algoritmo que se ha ejecutado en los experimentos.

También se muestran las relaciones del MSE y PSNR para evaluar la calidad de la partición obtenida, las componentes de los centros finalmente obtenidos y la imagen reconstruida a partir de los centros encontrados.

Finalmente, se hace una selección representativa de los puntos de las imágenes de muestras, clasificados de acuerdo con los grupos encontrados en el espacio R^3 de color RBG y una proyección mediante el análisis de componentes principales hacia un espacio en R^2 con fines de visualización de las agrupaciones de texturas encontradas.

Fuzzy Clustering

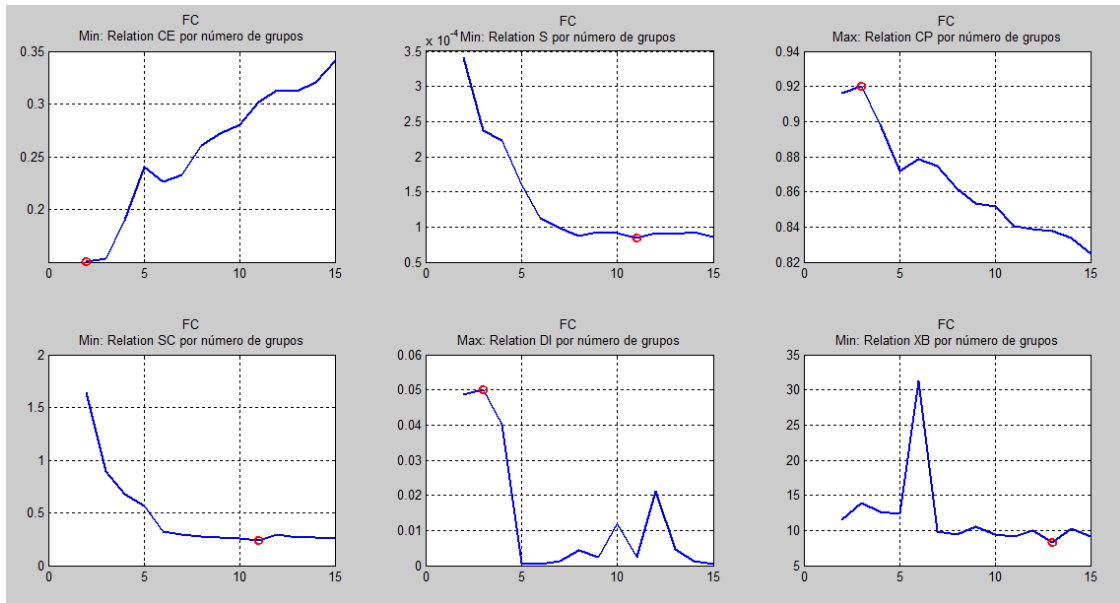


Figura 47. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones




Figura 48. Muestra 4: Gráficas de los indicadores MSE y PSNR

Tabla 9. Muestra 4: Centros aprendidos por el algoritmo FC

R	G	B
127	171	220
179	170	135
215	197	165
129	134	138
86	86	76
165	195	227
162	158	118
197	183	150
234	214	182
116	121	73
172	189	207
32	39	35
131	136	88
147	147	103
145	183	227

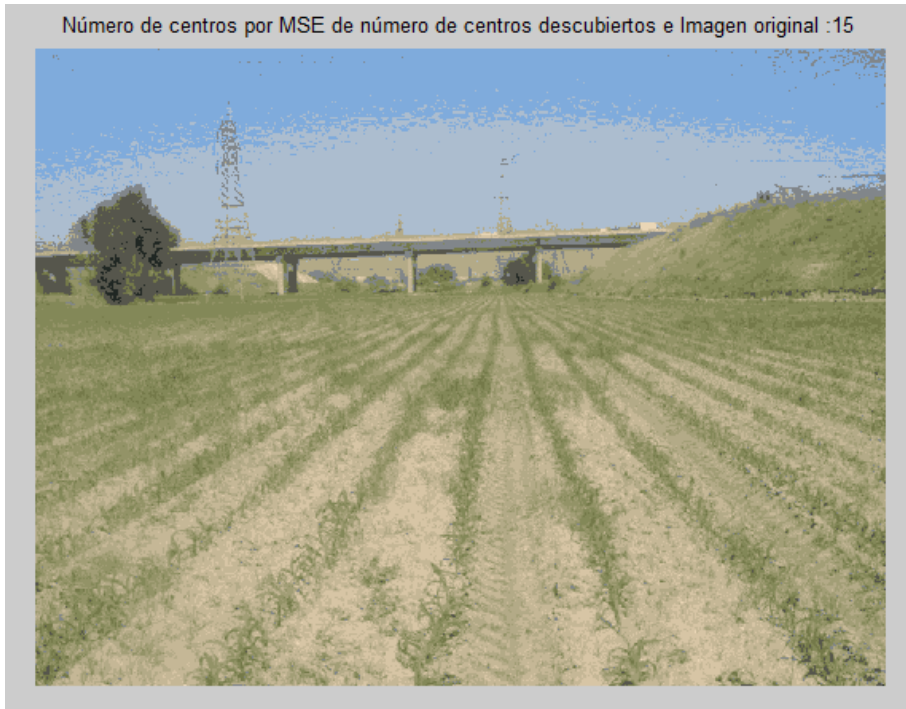


Figura 49. Muestra 4: Gráfica reconstruida desde FC de la imagen a partir de los centros aprendidos

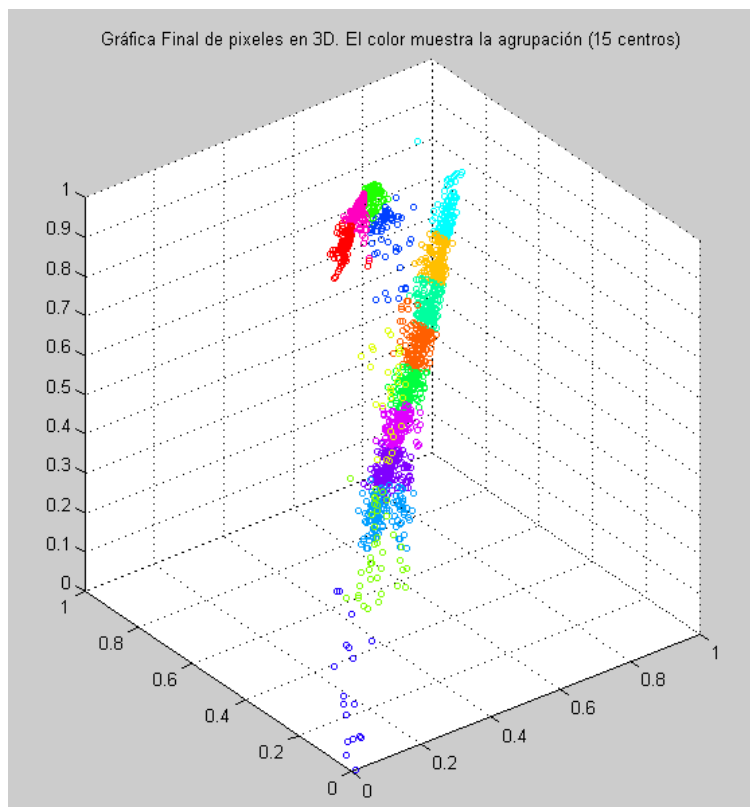


Figura 50. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por FC

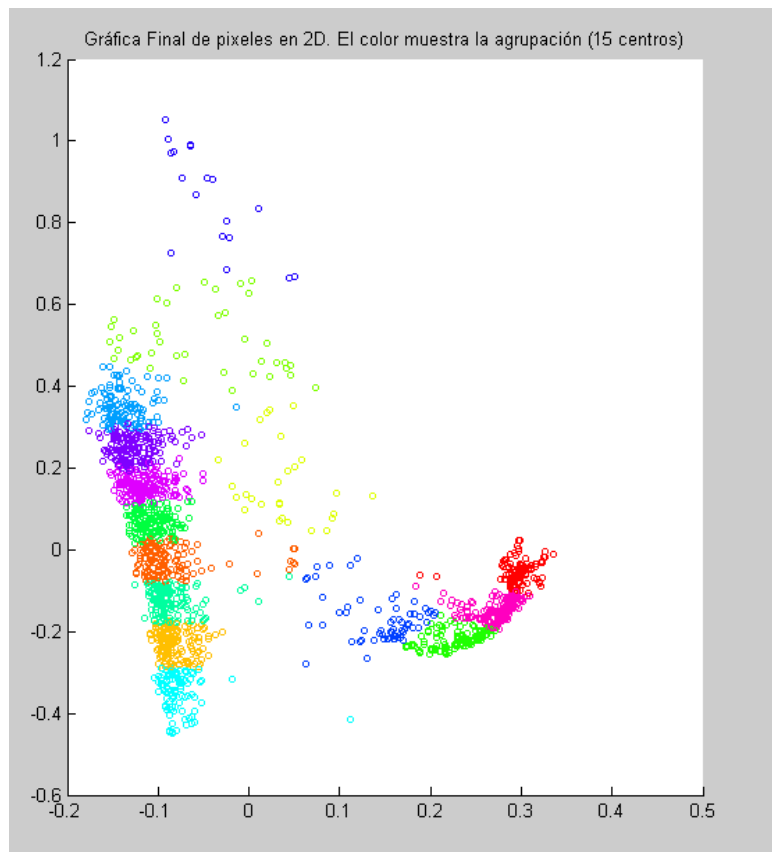


Figura 51. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por FC

Algoritmo: K-means

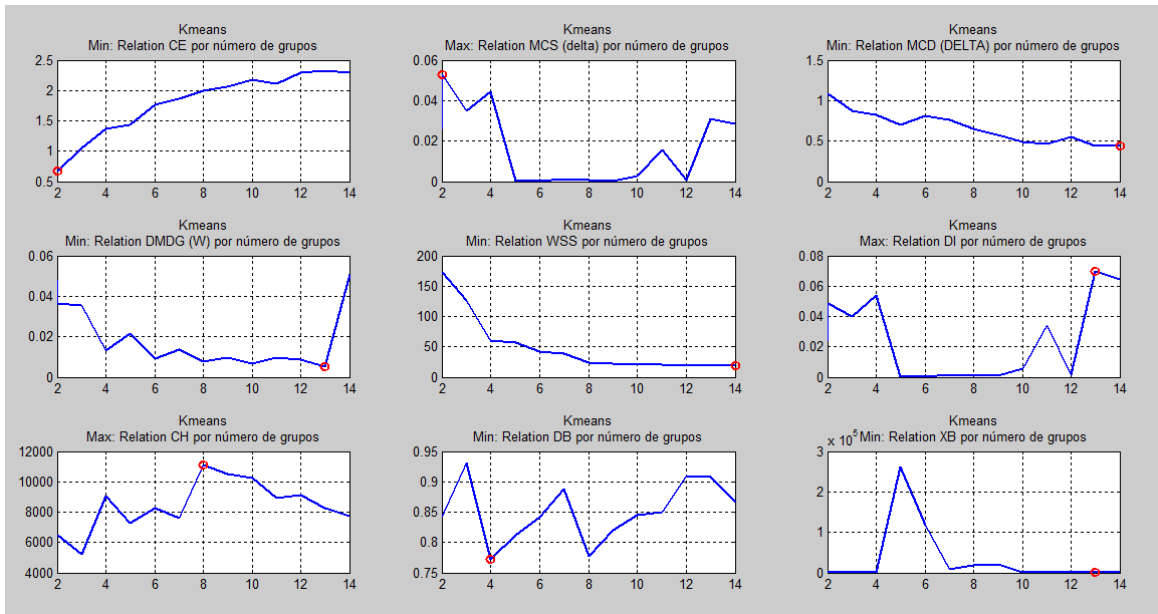


Figura 52. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones




Figura 53. Muestra 4: Gráficas de los indicadores MSE y PSNR

Tabla 10. Muestra 4: Centros aprendidos por el algoritmo K-means

R	G	B
146	168	186
116	124	120
181	171	147
107	113	93
156	154	125
141	145	109
167	162	135
136	135	109
196	182	159
144	149	146
75	89	74
147	149	117
132	141	101
125	132	95



Figura 54. Muestra 4: Gráfica reconstruida desde K-means de la imagen a partir de los centros aprendidos




Figura 55. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por K-means




Figura 56. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por K-means

Algoritmo: LVQ

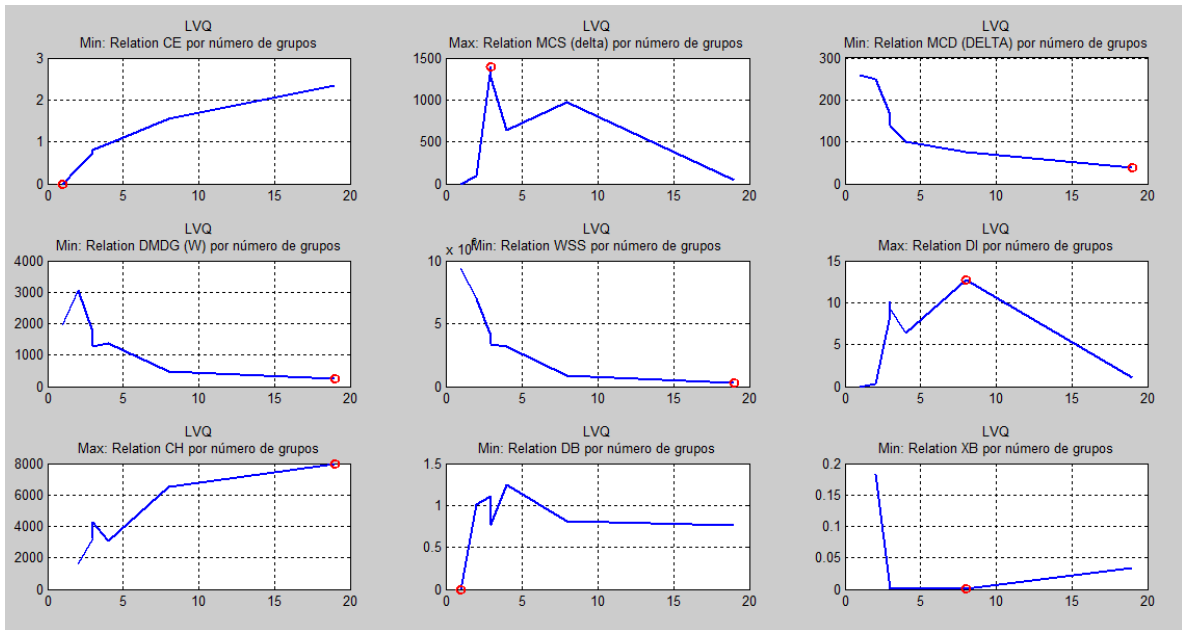


Figura 57. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones




Figura 58. Muestra 4: Gráficas de los indicadores MSE y PSNR

Tabla 11. Muestra 4: Centros aprendidos por el algoritmo LVQ

R	G	B
138	164	186
127	131	122
80	94	79
100	108	95
133	140	103
147	149	117
164	159	132
122	127	94
155	173	187
180	170	145
110	119	116
138	145	140
63	77	62
192	179	156
158	163	162
203	187	164
163	173	179
210	207	206
190	189	191



Figura 59. Muestra 4: Gráfica reconstruida desde LVQ de la imagen a partir de los centros aprendidos




Figura 60. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por LVQ




Figura 61. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por LVQ

Algoritmo: Mean Shift

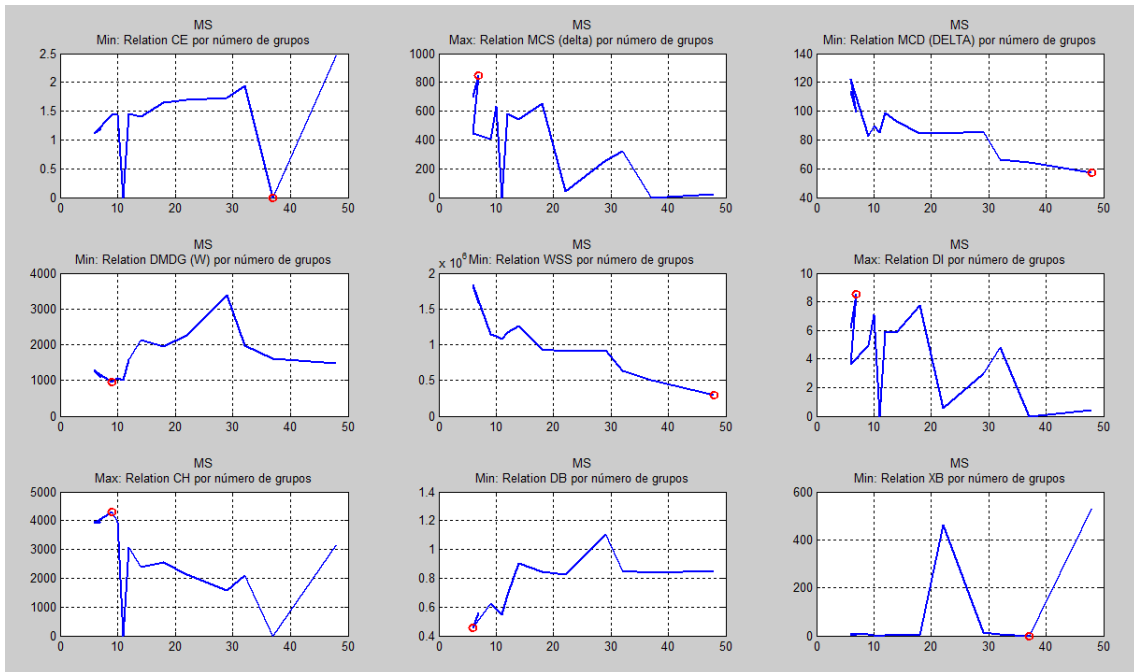


Figura 62. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones




Figura 63. Muestra 4: Gráficas de los indicadores MSE y PSNR

Tabla 12. Muestra 4: Centros aprendidos por el algoritmo Mean Shift

R	G	B
141	166	189
138	164	187
142	146	111
148	150	117
194	180	157
175	166	141
153	173	190
165	160	132
128	127	99
101	104	86
186	174	150

153	155	152
60	74	59
167	162	153
79	95	80
97	108	96
140	143	136
132	138	136
156	159	157
88	96	77
118	123	121
67	82	66
137	141	132
118	139	141
105	111	91
103	111	105
143	146	143
110	117	116
82	90	75
123	126	122
91	103	95
146	148	114
79	102	94
125	131	129
55	67	56
78	94	80
70	88	76
147	150	147
96	104	86
107	117	85
129	146	148
109	130	125
190	189	191
210	207	206
112	120	93
110	122	84
179	179	174
97	122	121

Número de centros por MSE de número de centros descubiertos e Imagen original :48



Figura 64. Muestra 4: Gráfica reconstruida desde Mean Shift de la imagen a partir de los centros aprendidos




Figura 65. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por Mean Shift




Figura 66. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por Mean Shift

Algoritmo: SOM

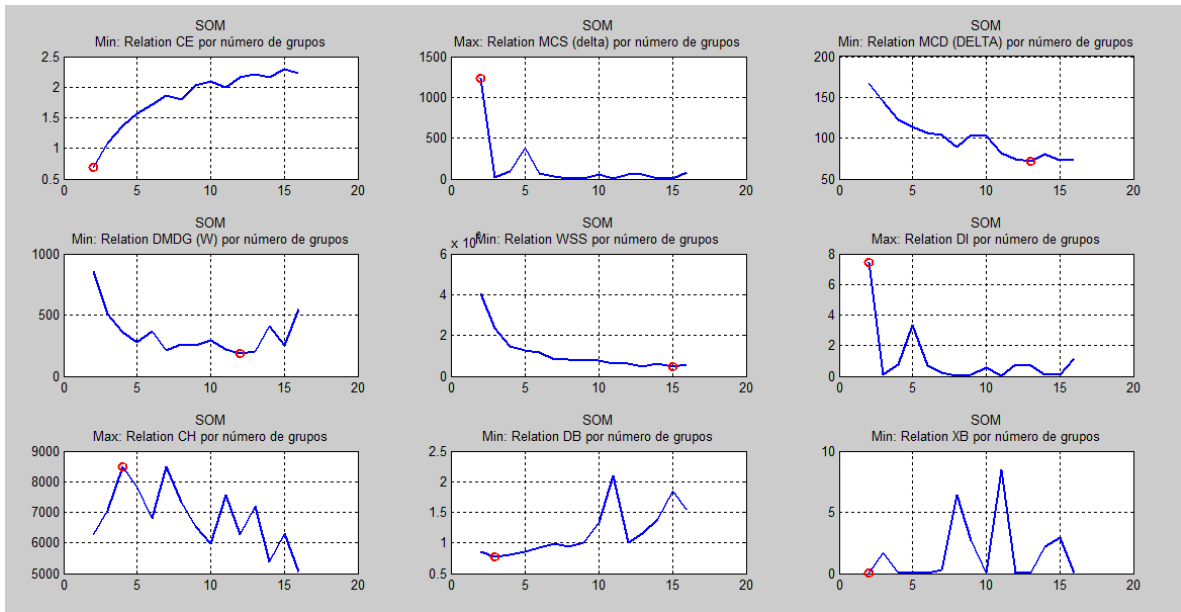


Figura 67. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones




Figura 68. Muestra 4: Gráficas de los indicadores MSE y PSNR

Tabla 13. Muestra 4: Centros aprendidos por el algoritmo SOM

R	G	B
185	175	153
169	163	140
68	80	67
119	123	90
104	77	177
89	100	87
78	182	204
156	155	131
148	148	119
149	169	185
132	137	105
133	161	182
196	184	161

Número de centros por MSE de número de centros descubiertos e Imagen original :13



Figura 69. Muestra 4: Gráfica reconstruida desde SOM de la imagen a partir de los centros aprendidos

Gráfica Final de pixeles en 3D. El color muestra la agrupación (13 centros)




Figura 70. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB, clasificados por SOM




Figura 71. Muestra 4: Gráfica de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por SOM

SOM + IC

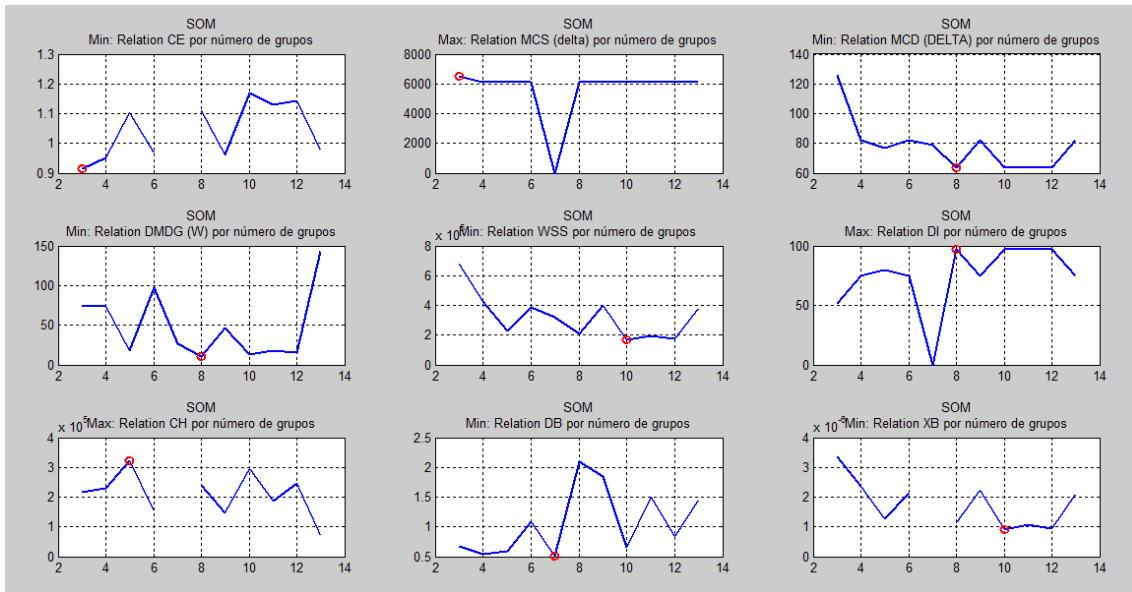


Figura 72. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones de vegetación

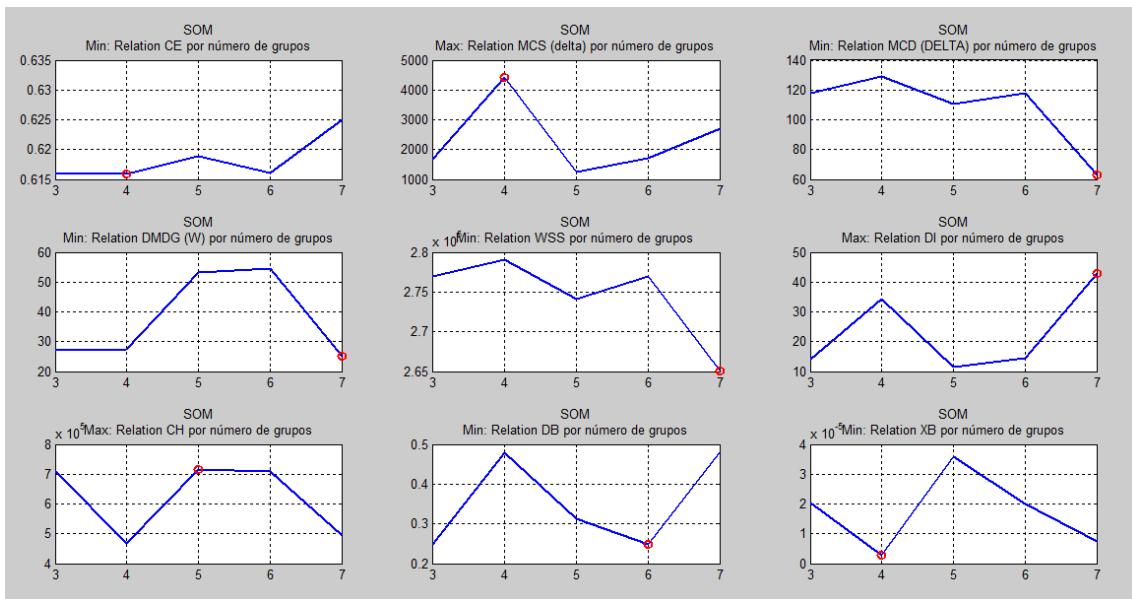


Figura 73. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones de suelo

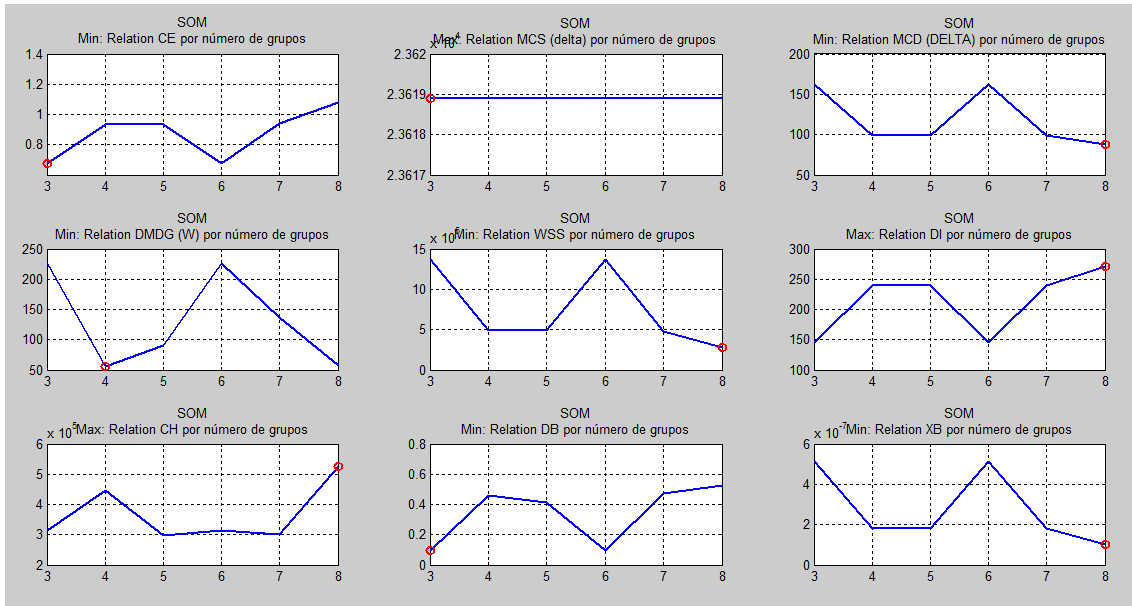


Figura 74. Muestra 4: Gráfica de los indicadores de calidad de agrupaciones de cielo

Tabla 14. Muestra 4: Centros aprendidos por el algoritmo SOM + IC

R	G	B
144	146	114
163	11	43
68	82	67
160	157	129
127	133	97
130	22	127
183	173	150
146	145	117
162	158	132
123	116	131
145	167	184
206	164	196



Figura 75. Muestra 4: Gráfica reconstruida desde SOM + IC de la imagen a partir de los centros aprendidos




Figura 76. Muestra 4: Gráfica de las agrupaciones finales de los puntos de la imagen del espacio RGB, clasificados por SOM + IC




Figura 77. Muestra 4: Gráfica de las agrupaciones finales de los puntos de la imagen del espacio RGB proyectados por PCA, clasificados por SOM + IC