

01170 5



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**

**FACULTAD DE INGENIERÍA  
DIVISIÓN DE ESTUDIOS DE POSGRADO**

TESIS

**MODELO MATEMÁTICO DEL PROCESO DE DESERTIFICACIÓN  
EMPLEANDO VARIABLES CANÓNICAS  
Y TÉCNICAS DE PERCEPCIÓN REMOTA**

PRESENTADA POR:

**NIDIYARE HEVIA MONTIEL**

PARA OBTENER EL GRADO DE:

**MAESTRA EN INGENIERÍA  
(ELÉCTRICA)**

DIRIGIDA POR:

**DR. JORGE LIRA CHÁVEZ**

CIUDAD UNIVERSITARIA, 2002.

**TESIS CON  
FALLA DE ORIGEN**



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

EN LA LISIS NO SALE  
DE LA BIBLIOTECA

*Dedicado a  
DIOS.  
"la imagen perfecta para mi vida"*

*Mis Padres  
Sergio y Martha.*

*Mis hermanos  
Edilia y Sergio.*

TESIS CON  
FALLA DE ORIGEN



## Agradecimientos

Al Dr. Jorge Lira, por haberme brindado la oportunidad de dirigir mi tema de tesis, haberme abierto las puertas a la percepción remota y el tratamiento de imágenes, así como por mostrarme en todo momento su apoyo y confianza....

Al Instituto de Geofísica de la Universidad Nacional Autónoma de México, por las facilidades otorgadas a través de sus instalaciones....

A la División de Estudios de Posgrado de la Facultad de Ingeniería de la Universidad Nacional Autónoma de México, por haberme albergado para realizar mis estudios y a quien debo mi formación profesional...

Al Ing. Miguel Ángel Zenteno y al Ing. Fernando Lazcano de SICORI, PEMEX, por haberme asistido y apoyado incondicionalmente en la obtención de material para la realización de esta tesis, así como por su tiempo y facilidades otorgadas....

A Ricardo, por haberme mostrado con entusiasmo el camino hacia el Laboratorio de Percepción Remota y puesto en mí el interés de adentrarme en el procesamiento digital de imágenes....

A Eduardo, un buen amigo, que a pesar de la distancia, me ha motivado en momentos especiales a seguir adelante....

A Alfredo, por haber permanecido en todo momento a mi lado, por brindarme su apoyo aunque no se lo pidiera, por recordarme que siempre debo de creer en mí, por alentarme en los momentos difíciles y compartir su tiempo conmigo, porque eres un ejemplo a seguir, por ser un amigo excepcional....

A mis compañeros del Laboratorio de Percepción Remota del Instituto de Geofísica, por su compañía y comprensión durante mi estancia en el laboratorio....

TESIS CON  
FALLA DE ORIGEN



# ÍNDICE

INTRODUCCIÓN .....	9
1. ANTECEDENTES.....	11
1.1. Percepción Remota.....	11
1.2. Procesamiento digital de imágenes.....	15
1.3. Imágenes de satélite.....	22
1.4. Imágenes de Radar (SAR).....	25
2. DESERTIFICACIÓN.....	29
2.1. ¿Qué es la Desertificación?.....	31
2.2. ¿Por qué ocurre la desertificación?.....	32
2.3. Indicadores del proceso de la Desertificación.....	34
2.4. Percepción Remota y Desertificación.....	35
3. EVALUACIÓN DE TEXTURAS.....	39
3.1. Mecanismos de degradación: Ruido.....	40
3.1.1. Filtros.....	43
3.1.1.1. Filtros en el dominio de la imagen.....	44
3.1.2. Criterios de evaluación de la calidad de una imagen.....	50
3.1.2.1. Descriptores Globales.....	51
3.1.2.2. Descriptores Locales.....	53
3.1.2.3. Histograma.....	56
3.1.2.4. Detección de Bordos.....	57
3.1.3. Comparación de Descriptores.....	59
3.1.3.1. Pruebas realizadas.....	59
3.1.4. Modelos de Texturas.....	64
3.1.5. Descriptores de Texturas.....	67
3.2. Modelo de divergencia.....	70
3.2.1. Campo vectorial de la imagen multiespectral.....	71
3.2.2. Operador de divergencia.....	72
3.3. Comparación de textura-radar vs. textura-divergencia.....	73
4. MODELO MATEMÁTICO DEL PROCESO DE DESERTIFICACIÓN.....	77
4.1. Expansión canónica.....	77
4.2. Indicadores de la desertificación.....	79
4.2.1. Albedo (Primera Componente Principal).....	80

4.2.2. Textura (Operador de Divergencia).....	82
4.2.3. Vigor de vegetación y Humedad del terreno (TSAVI).....	83
4.3. Combinación de indicadores.....	87
5. RESULTADOS.....	93
5.1. Correlación entre las bandas canónicas.....	97
5.2. Distancia de Jeffries-Matusita.....	97
6. CONCLUSIONES.....	99
7. REFERENCIAS.....	101
ANEXO A. Corrección Geométrica, registro de imágenes y Localización.....	109
ANEXO B. Resultados obtenidos de los criterios de evaluación de la calidad de una imagen.....	117

## INTRODUCCIÓN.

Un método de observación a distancia de un sistema físico que ha cobrado gran importancia es la Percepción Remota, la cual ha tenido un desarrollo acelerado y se ha llegado a convertir en una rama de la ciencia. La percepción remota utiliza métodos eficientes de análisis de imágenes, arquitecturas computacionales y fabricación de sensores, en la actualidad esta nueva rama de la ciencia nos permite resolver diversos problemas dentro de la investigación experimental. Estas observaciones o mediciones hechas a distancia, con la ayuda de satélites, llegan a formar una colección de datos en forma de imágenes que tienen que ser procesadas digitalmente por computadoras, por lo que no se puede pensar en la percepción remota sin el uso del tratamiento digital de imágenes.

El análisis de imágenes se emplea en diversas áreas científicas, en el área de la percepción es un gran apoyo para la prospección de los recursos naturales y el medio ambiente, se puede aplicar a ciencias como la geología, geografía, geofísica y en áreas como la agricultura, silvicultura y urbanismo, así como en la protección de los recursos terrestres. El reciente desarrollo de satélites para la observación de los recursos naturales prevé el inicio de una nueva etapa en el tratamiento de datos geográficos, uno de los estudios que tienen gran relevancia en este aspecto es el proceso de desertificación a través de sensores remotos y con la ayuda de imágenes tomadas a distancia, por lo que han surgido métodos para localizar, evaluar y monitorear el cambio en un paisaje que provoca este fenómeno con el uso de técnicas de la percepción remota.

Durante las últimas décadas en México se han registrado cambios drásticos, al mantener un crecimiento de la población, una urbanización y una industrialización aceleradas y al modificar las políticas relativas al campo, provocando alteraciones irreversibles sobre superficies que anteriormente conformaban los ecosistemas terrestres del país. México actualmente se encuentra afectado por el proceso de desertificación en un 64% de su territorio.

A partir de la presencia de este fenómeno de desertificación en nuestro país y del análisis sobre el problema que puede generarse ante un continuo proceso de este fenómeno es como se ha despertado una inquietud por encontrar métodos y medios para monitorear, prevenir y controlar cierto fenómeno.

Con base en lo anterior es como surge el interés de realizar el presente trabajo de tesis: *un modelo matemático del proceso de desertificación empleando variables canónicas y técnicas de percepción remota*, en el Laboratorio de Percepción Remota del Instituto de Geofísica, UNAM, bajo la dirección del Dr. Jorge Lira Chávez.

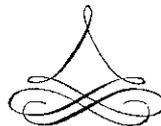
Este trabajo se encuentra dividido en siete capítulos y dos anexos. En el primer capítulo se tienen los antecedentes sobre lo que es la percepción remota y el tratamiento de imágenes digitales, así como una breve explicación de las imágenes de satélite y radar. En el capítulo dos se tiene una presentación y un análisis acerca del proceso de desertificación, cómo se le define, el por qué ocurre dicho fenómeno, sus indicadores y la relación que existe entre la percepción remota y la desertificación.

En el capítulo tres se presenta una evaluación de texturas realizadas a las imágenes, tanto imagen de radar como imagen multiespectral, que se utilizaron como variables en el modelo matemático posteriormente descrito. Este capítulo comienza con una explicación sobre los mecanismos de degradación presentes en una imagen de radar, así como una serie de filtros que se utilizaron para mejorar la calidad de esta imagen, seleccionándose el filtró que arrojó los mejores resultados en base a una serie de descriptores. Así mismo, este capítulo cuenta con dos anexos mostrados al final de esta tesis con los resultados obtenidos de la evaluación de la calidad de la imagen. Posteriormente, se obtuvieron dos imágenes de textura a través de dos modelos diferentes, al realizar una comparación entre ambas se seleccionó la mejor imagen.

En el capítulo cuatro se muestra el desarrollo que se llevó a cabo para obtener un mapa de niveles de desertificación a partir de una imagen multiespectral, mediante un modelo matemático de desertificación donde se emplean tres variables como son el albedo, la textura y un índice de vigor de la vegetación y humedad del terreno. Al final del capítulo se muestra como se realizó una combinación de estas variables o indicadores de la desertificación para la obtención del mapa de niveles de desertificación.

En el capítulo cinco se analizan los resultados obtenidos con el mapa de niveles de desertificación, así como se verifica que no existe una correlación muy alta entre las variables que se emplearon en el modelo matemático.

Este trabajo de tesis se termina haciendo las conclusiones pertinentes al respecto dadas en el capítulo seis y se muestra en el capítulo siete una lista de las referencias bibliográficas que se consultaron para la realización de esta tesis.



# CAPÍTULO UNO

## ANTECEDENTES.

“Los satélites artificiales, los sensores remotos y el manejo de imágenes digitales por medio de computadora, han modificado el estudio de la superficie terrestre y la evaluación de los recursos naturales” (Lira,1987).

Con el objeto de que el lector tenga el marco conceptual necesario para la comprensión del trabajo aquí presentado, este primer capítulo describe los temas principales y conceptos básicos referentes a percepción remota, imágenes digitales, tratamiento de imágenes, así como también detalles técnicos de imágenes de satélite y radar.

En este capítulo se busca que el lector se familiarice con ciertos términos y conceptos para que en el transcurso de la presente tesis le sirvan como una herramienta y apoyo. El capítulo se encuentra dividido en cuatro secciones: Percepción Remota, Procesamiento Digital de Imágenes, Imágenes de Satélite e Imágenes de Radar (SAR), de donde se partirá para adentrarse en el tema y objetivo específico de esta tesis.

### 1.1. Percepción Remota.

La Percepción Remota puede ser definida como la ciencia y el arte de obtener información relacionada con un objeto, un área o un fenómeno a través del análisis de

datos adquiridos por medio de un dispositivo que no está en contacto físico con el objeto, área o fenómeno bajo investigación (Lillesand y Kiefer, 1987).

Si bien lo anterior es una definición, a continuación se hará comprender al lector de una manera práctica y sencilla el concepto de Percepción Remota. El ser humano por naturaleza ha tenido siempre la inquietud de explorar todo lo que le rodea, incluyendo las cosas que pueden encontrarse fuera de su alcance; gracias a esto el hombre ha logrado descubrir nuevas cosas y esto se ve en el desarrollo de la tecnología. Podemos ver que existen dos maneras en que el hombre puede analizar las cosas que le rodean: de manera directa o indirecta. Si hablamos de un análisis de forma directa lo que se requiere es tener contacto físico con los objetos de nuestro interés, es decir, tocando o probando el objeto; en cambio, si una persona está analizando el lugar que lo rodea sin tener contacto físico con los objetos, es decir, sólo haciendo uso de su vista, oído y olfato entonces estaríamos hablando de un análisis indirecto del lugar que lo rodea. De esta idea podemos partir para comprender la ciencia de la percepción remota, ya que lo que se realiza es un análisis de ciertos objetos de estudios pero sin tener un contacto físico.

Si comparamos la experiencia de un hombre que haya vivido en la época de la prehistoria con un hombre que viva en el siglo XXI, podemos observar que en el primer caso lo más probable es que esta persona haya tenido solo contacto físico con todo lo que le rodeaba en su ambiente, quizás no podía ver mas allá de ciertos límites, caso muy diferente con el hombre que vive en nuestros días, ya que este puede observar y analizar el planeta Tierra viéndolo desde el exterior, así como superficies de otros planetas y realizar un análisis sobre lo que puede observar sin la necesidad de realizar un contacto físico con los objetos.

Dentro de la ciencia de la Percepción Remota se identifican los siguientes elementos básicos:

- Fuente de Iluminación
- Paisaje
- Escena
- Sensor Remoto
- Plataforma
- Sistema de Procesamiento
- Apoyo de Campo

Supongamos el siguiente ejemplo muy simple para poder identificar cada uno de estos elementos mencionados, imaginemos a una persona que se encuentra subiendo hacia lo alto de una montaña, al momento de llegar a la cima logra ver que del otro de la montaña se encuentra un llano muy amplio, en donde a su vez hay un lago, árboles e incluso alcanza a ver que a la orilla del lago se encuentran unos animales bebiendo agua. Antes de identificar en el ejemplo a cada uno de los

elementos que comprenden a la percepción remota, se deben de tener presentes los siguientes conceptos:

**Fuente de iluminación.-** La fuente de iluminación puede ser de tipo externa o interna, donde los sistemas que utilizan una fuente de iluminación externa son llamados sistemas pasivos y a los que utilizan una fuente de iluminación interna se les llama sistemas activos. En un sistema pasivo la fuente de iluminación puede ser el sol o alguna estrella lejana, en tal caso se debe de esperar que se tengan las condiciones de iluminación adecuadas y tener cuidado en las características que se deseen. Por otro lado los sistemas activos cuentan con su propia fuente de iluminación, es por ello que estos sistemas son los que han permitido que se puedan estudiar fenómenos en donde no se tiene una fuente de iluminación externa, por lo que se pueden encontrar provistos de luz ultravioleta o infrarroja, así como de rayos gama o rayos X, lo cual ayuda a que las aplicaciones de la percepción remota sean diversas.

**Paisaje.-** El paisaje está formado por el sistema físico u objetos<sup>1</sup> que son los que interesa estudiar o analizar, por esto sería el elemento más complejo dentro de la percepción remota debido a que intervienen infinidad de factores y no se pueden llegar a controlar en su totalidad todos los aspectos que lo conforman. Todo esto puede llegar a dar como resultado una sobrestimación o una sobre-simplificación del paisaje que se esté observando, ocasionando a la vez errores de operación y diseño.

**Escena.-** Es una sección o superficie que forma parte de un paisaje, dentro de la cual se tendrán ciertas entidades no físicas en las que se tendrá enfocado un interés en particular para analizar y estudiar, es decir, es solo una parte del paisaje.

**Sensor remoto.-** Es el dispositivo con el cual se captura la radiación (ya sea visible o invisible) que proviene de la escena para poder tener una representación de la misma. Se tienen dispositivos o detectores que proporcionan la representación de la escena o imagen en forma cuantitativa. Algunos ejemplos de detectores pueden ser una placa radiográfica, una película fotográfica infrarroja, fotodetectores, cámaras de televisión, entre otros.

**Plataforma.-** Estaría compuesta por el lugar donde se encuentre montado el dispositivo o sensor remoto para poder obtener en conjunto la imagen de la escena, donde la imagen que se observe dependerá de la distancia de observación a la cual esté colocada la plataforma, así mismo el detalle o grado de discernimiento que se pueda tener en la imagen. Se debe tener presente con que tipo de detectores se cuenta, si son de alta o baja resolución<sup>2</sup>, así como la aplicación para la cual se utilizará, ya que

---

<sup>1</sup> Un objeto es considerado como un ente físico o materia formado por varios elementos químicos o físicos.

<sup>2</sup> Resolución es la capacidad que tiene un sensor para separar los elementos de un objeto bien definido como una sucesión de líneas equidistantes

pueden existir plataformas que se encuentren tanto a una gran distancia como a una distancia muy corta de la escena.

**Sistema de procesamiento.-** Este elemento se encuentra formado por un dispositivo que procesa, de manera cuantitativa o cualitativa, los datos que han sido proporcionados por el sensor remoto, ya sea en forma analógica o digital, para tener así una representación continua o discreta de la escena. Existen sistemas de procesamiento con un rango muy amplio de algoritmos<sup>3</sup> para el análisis de imágenes, las cuales pueden ser analizadas de manera digital y obtener información que pueda ser extraída, representada o manipulada de alguna manera para poder hacer una toma de decisiones con respecto a uno o varios aspectos de la imagen, es decir, se tiene un sistema de información y la toma de decisiones es un proceso cuantitativo.

**Apoyo de campo.-** El apoyo de campo se refiere a las técnicas con las cuales se puede hacer una inspección cualitativa y cuantitativa de ciertos aspectos u objetos del paisaje, éstas se obtendrían como resultado de los métodos de muestreo estadístico así como de las propiedades físicas y químicas de los objetos que se encuentren presentes en la escena. Hay que resaltar que una observación directa de ciertos puntos de la escena sería necesaria para que se lleve a cabo una validación correcta de lo que se está observando.

Ahora bien, volviendo a nuestro ejemplo inicial y una vez que se tiene el concepto de cada uno de los elementos básicos que conforman la ciencia de la percepción remota, podríamos decir que la fuente de iluminación sería el sol, es decir, en este caso se trata de una fuente de iluminación externa; el paisaje estaría formado por todos los objetos que la persona pueda observar en el prado, como el lago, los árboles, los animales, entre otros; si suponemos que a la persona lo que le interesa es saber que animales son los que se encuentran tomando agua a la orilla del lago, entonces la escena sería solo el área o la superficie donde se encuentran los animales; el sensor remoto serían los ojos de esa persona, la plataforma sería en sí la misma persona que se encuentra en lo alto de la montaña, el sistema de procesamiento estaría representado por su cerebro, ya que es donde se está procesando y formando la imagen que la persona está observando y el apoyo de campo serían las características o aspectos que el hombre logre obtener al acercarse a la escena e inspeccionar de manera más directa.

Es así como la Percepción Remota se encuentra definida de manera muy general como la colección de información acerca de un objeto sin estar en contacto físico con el mismo (Lira, 1987).

---

<sup>3</sup> Algoritmo es una sucesión lógica de instrucciones que proporciona al sistema computacional las órdenes que se requieren para ejecutar una tarea en particular.

Ahora bien, hay que tener presente que el término de Percepción Remota se encuentra restringido a métodos que emplean energía electromagnética como el medio de detección y medición de las características del objeto, así como también se hace con radar, es decir, no se consideran mediciones eléctricas, magnéticas y de gravedad con las que se miden campos de fuerza (Floyd y Sabins, 1978).

El desarrollo de la Percepción Remota se ha venido incrementando y debido a su aplicación en ciencias como la geografía, geología, geofísica e incluso en cualquier ciencia que tenga que ver con el estudio de la superficie terrestre en general, así como el poder evaluar el medio ambiente y apoyar en labores de protección de los recursos terrestres, pero eso no quiere decir que la Percepción Remota se limite solo a medio ambiente, sino que puede ser aplicada en una gran diversidad de sistemas físicos, como en el campo de la medicina, la criminalística, la astronomía, entre otros.

## 1.2. Procesamiento digital de imágenes.

A mediados de los años sesenta, las primeras imágenes capturadas por sondas espaciales marcaron una pauta bien definida en el desarrollo del Procesamiento Digital de Imágenes. En 1964 las escenas de la luna que fueron transmitidas por el Ranger-7 se procesaron por medio de una computadora para poder corregir varios tipos de distorsión en la imagen, inherentes a la cámara de televisión que se llevaba a bordo (Gonzalez y Wintz, 1987). La percepción remota está basada en el procesamiento digital, el análisis de imágenes multiespectrales y el reconocimiento de patrones. Algunas de las aplicaciones de este campo son: la predicción del clima, clasificación y monitoreo de ambientes urbanos, agrícolas y marinos, evaluación del medio ambiente y desastres naturales, caracterización del tipo de suelos, texturas del terreno, entre otras, todo esto a partir de imágenes de satélite.

En términos generales el procesamiento digital de imágenes involucra la manipulación e interpretación de imágenes digitales con la asistencia de una computadora (Rosenfeld, 1982; Jain, 1989; Pratt, 1991), donde uno de los intereses básicos se encuentra en la transformación de los datos multiespectrales para poder relacionarlos con un marco de referencia adecuado y así poder tener su análisis e interpretación de la imagen. Un segundo interés es la extracción particular de ciertos rasgos o características de una imagen con el objeto de apoyar un análisis automático de tales datos. De todo esto se puede decir entonces que el procesamiento digital de imágenes es el conjunto de transformaciones al espacio donde se encuentran originalmente los datos, con el objeto de realzar un cierto conjunto de patrones (Pastrana, 1996).

El análisis de imágenes se descompone básicamente en dos grandes grupos de transformaciones<sup>4</sup>: el Procesamiento Digital y el Reconocimiento de Patrones. En una imagen digital los objetos de interés o patrones no siempre se encuentran en la representación o con la evidencia deseadas, de tal forma que es necesario realzarlos antes de proceder a realizar una transformación en los mismos. Debido a esto, al grupo de procesamientos realizados a la imagen se les conoce como realce de patrones. El Procesamiento digital de imágenes se divide a su vez en tres: Realces Globales, Realces Selectivos y Restauraciones. En el primer grupo la imagen se realiza como un todo sin quitar ni añadir información. En el segundo grupo, donde a este tipo de realces se les conoce también como filtrajes, se realiza selectivamente una clase de patrones, generalmente a costa del resto de la información de la imagen. En las restauraciones o realces de fidelidad, se supone que la imagen ha sido degradada por algún mecanismo de degradación conocido, a partir de cuyo modelo se construye una imagen ideal, es decir, como se hubiese generado en ausencia de la degradación y a partir de un modelo matemático de restauración se transforma la imagen degradada para que se parezca lo más fielmente posible al modelo de imagen ideal.

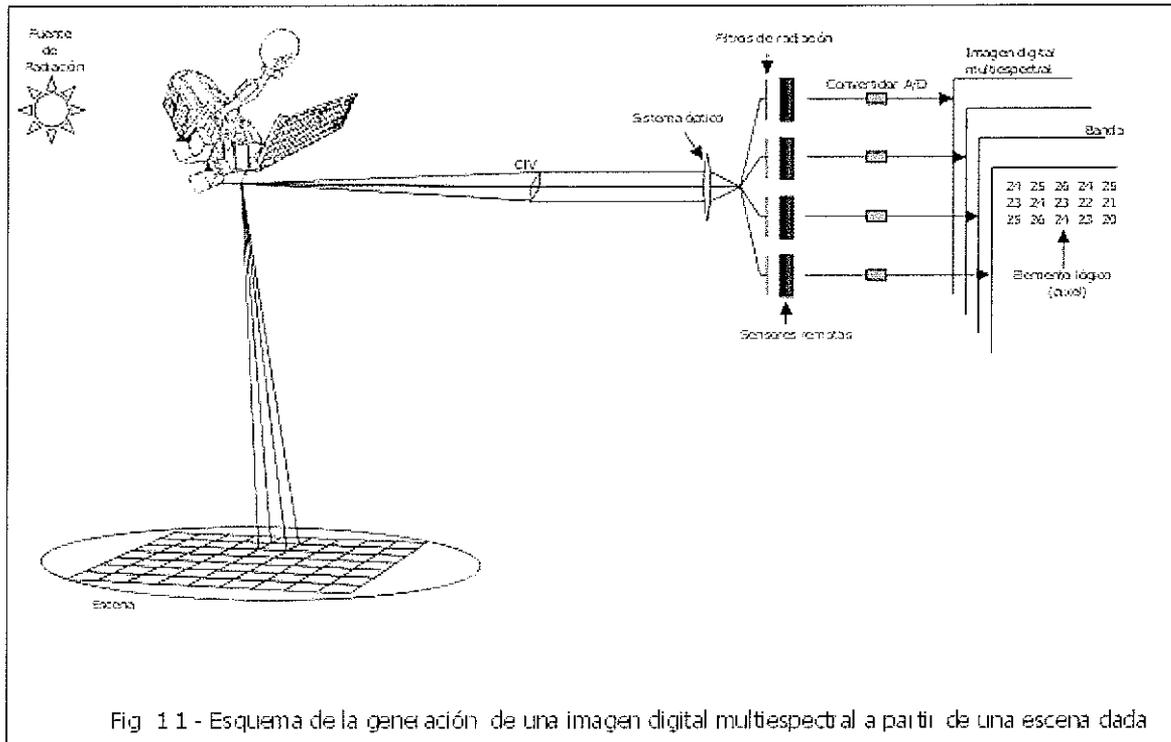
Es importante recalcar que el procesamiento digital de imágenes es el núcleo básico de cualquier sistema de análisis de imágenes. Por lo que se puede decir entonces que el procesamiento digital de imágenes es el conjunto de realces bien definidos y clasificados, que dejan lista la imagen para poder hacer una descripción matemática de las regiones que la componen.

Ahora bien, después de haber explicado acerca del procesamiento y análisis digital de imágenes, así como de las partes que la componen, pasemos a ver cómo es que se llegan a generar estas imágenes digitales.

Primero identificaremos los elementos que componen a una imagen digital, para esto veamos la ilustración que se muestra en la Figura 1.1.

---

<sup>4</sup> Transformaciones son el conjunto de modelos matemáticos diseñados para extraer información específica relativa a la escena de interés.



Como puede observarse se debe de tener una fuente de iluminación o de radiación, donde esta radiación puede ser del tipo ondulatoria o corpuscular, la cual se encuentra separada del sistema físico. No obstante, también pueden utilizarse como fuente de radiación los rayos X o haces de neutrones, donde esta radiación mas bien estaría atravesando la escena que estuviéramos estudiando.

Ahora bien, continuaremos definiendo un nuevo concepto, dentro de la escena se debe de contar con un cierto elemento físico que es el Campo Instantáneo de Vista (CIV), el cual es una subregión de la escena que forma parte del sistema físico. Una vez que se ha emitido radiación a través de la fuente se hace interaccionar el CIV con esta radiación, dando como resultado el que se refleje una nueva radiación que no debe ser igual a la que se tenía originalmente. Una parte de esta radiación, que es reflejada por el CIV, es captada por un arreglo de detectores que contienen a su vez un subsistema de enfoque y de conducción de la radiación, donde los detectores miden la cantidad de radiación por ángulo sólido por unidad de tiempo. Enfrente de los detectores se encuentra un conjunto de filtros, los cuáles tienen como función seleccionar ciertos intervalos de energía  $\{\Delta E_1, \Delta E_2, \dots, \Delta E_3\}$  o de longitudes de onda  $\{\Delta \lambda_1, \Delta \lambda_2, \dots, \Delta \lambda_3\}$ , dependiendo de los intervalos para los cuales fueron diseñados cada uno de los detectores y es posible que para un sólo intervalo se tengan varios detectores, esto dependería de si la radiación que se esté midiendo sea de un CIV o de un grupo de estos.

Una vez que la radiación ha sido conducida a los detectores y filtrada de acuerdo a ciertos intervalos, se obtiene, como resultado de la integración de esta radiación, una señal de voltaje que es introducida a un convertidor analógico/digital a medida que se van observando los CIV's. La función de este convertidor es cuantizar la señal de voltaje, donde la escala que generalmente se utiliza es de 0 a 255 niveles de gris, aunque pueden llegar a utilizarse otras escalas. Es de esta forma que para cada intervalo de energía y para cada CIV se genera un número cuyo valor se almacena en algún medio magnético u óptico, donde se le asigna una posición lógica que corresponde con el lugar relativo que tiene el CIV en la escena.

Entonces podemos decir que por cada CIV se producen  $\gamma$  números que en conjunto describirán la respuesta espectral del CIV, estos valores pueden ser arreglados de manera vectorial y representados mediante la siguiente expresión

$$p_{mn} = \{b_1, b_2, \dots, b_\gamma\}_{mn} \quad (1.2)$$

donde  $b_i$  es el valor obtenido para el intervalo de energía  $\Delta E_i$  y debe encontrarse dentro del siguiente rango  $0 \leq b_i \leq 2^k - 1$ , donde el valor de  $k = 8$  en la mayoría de los casos. La colección de estos números es lo que se conoce como píxel<sup>5</sup>, se puede decir que el píxel es la caracterización numérica de las propiedades radiométricas promedio de un CIV o bien definirlo como un elemento lógico de la imagen digital. Y, por último, los índices (m,n) representan las coordenadas del píxel en su posición dentro de la imagen digital, por lo que

$$b_i \rightarrow \Delta E_i \rightarrow \Delta \lambda_i \quad (1.3)$$

de modo que

$$\Delta E_{i+1} > \Delta E_i, \text{ o } \Delta \lambda_{i+1} > \Delta \lambda_i \quad (1.4)$$

Hay que tener presente que las características espectrales de un CIV estarían representadas por el píxel correspondiente, así como su posición y su tamaño relativo dado por la siguiente relación unívoca

$$\text{CIV} \Leftrightarrow \text{píxel} \quad (1.5)$$

Es necesario resaltar la diferencia entre el concepto de un CIV y un píxel, donde el primer término se refiere a un elemento físico de la escena y el segundo término sería un elemento lógico de la imagen digital, el cual no tiene dimensión asociada.

<sup>5</sup> píxel viene de la abreviación de 'picture elements'

Se miden de igual forma todos los CIV's de una escena y se obtiene de esta forma, para cada uno de los intervalos de energía que se hayan utilizado, una colección de matrices de números cuyas dimensiones son de  $N \times M$ . A cada una de estas matrices se le conoce como banda, la cual se puede definir como una imagen digital, ya que representa la distribución espacial de valores de radiación provenientes de la escena para un intervalo de energía. Y al conjunto de estas bandas o matrices se conoce como Imagen Digital Multiespectral, debido a que no sólo caracteriza la distribución espacial sino también la distribución espectral de la radiación. Dado que una imagen multiespectral requiere de un espacio de  $\gamma$  dimensiones para representar los píxeles que la componen, una imagen multiespectral también se puede representar como un campo vectorial, donde los píxeles son vectores de tantos elementos como bandas se hayan generado, por lo que un píxel es un elemento digital básico de una imagen multispectral.

Posteriormente, la imagen digital multiespectral es almacenada en algún dispositivo magnético u óptico con el objeto de poder desplegar y visualizar la imagen digital en algún monitor o pantalla. Este proceso se hace mediante la lectura del valor de cierto píxel y se transfiere a la pantalla como un punto que posee una tonalidad en niveles de gris o color de manera proporcional a su valor, en la posición que le corresponde, es decir, se asignan tonalidades a los valores de los píxeles donde esta asignación de tonos se hace por medio de una función de color, representada en ocasiones a través de una tabla. Dicha representación visual puede tener tres modalidades:

- 1.- Tonos de grises - Donde se despliega una sola banda, es decir, un elemento de píxel. Generalmente se asigna un tono negro a un valor 0 y un tono claro al 255 y grises a valores intermedios.
- 2.- Pseudocoloración - Donde se despliega una sola banda y los valores de los píxeles se subdividen en intervalos, asignando a cada uno de éstos un conjunto de tonos de un cierto color.
- 3.- Falso color - Donde se despliegan tres bandas asignando a cada una de ellas tonos de los colores primarios rojo, verde y azul.

Otro concepto que se utiliza en el procesamiento digital de imágenes es el de *patrón*, donde una definición general (Lira, 2001) es la siguiente:

**Patrón:** Arreglo de entes de la misma naturaleza.

En relación con el arreglo si sólo se llegaran a intercambiar dos elementos de una serie, entonces se tendría un patrón diferente, cabe mencionar que existen dos posibles clases de arreglos: de orden lógico (respuesta espectral) y de orden físico (dimensión espacial); y aunque no se especifique en la definición a qué tipo de entes

se refiere, únicamente estaría restringido en cuanto a su naturaleza, por lo que no se pueden combinar entes de diferente tipo. De esta forma, en una imagen multiespectral se tienen bandas, las cuales son arreglos de píxeles, donde cada uno de los píxeles que la forman es un patrón de orden lógico y como éstos representan la respuesta espectral de los CIVs de la escena, decimos que un píxel es un patrón espectral de orden lógico.

Existe una enorme variedad de patrones espaciales, pero existen algunos de ellos que son de particular interés en el análisis de imágenes digitales. Se introducirá una nueva definición (Lira, 2001) que ayudará a poder identificar estos tipos de patrones:

**Clase de patrones** - Conjunto de patrones con características similares.

Dado que puede ser aplicada la definición tanto para patrones espaciales como espectrales, se entenderá por propiedades similares a todas aquellas características morfológicas o espectrales que son comunes y de interés en un problema, siempre que se agrupen píxeles espectrales se tendrá a la vez un patrón espacial y viceversa, por lo que la interrelación entre unos y otros es estrecha debido sobre todo a la naturaleza espacial y espectral de la imagen digital multiespectral, por lo que podría hablarse también de Clase Espectral y Clase Espacial. Sin embargo, lo que interesa en la definición de una clase de patrones es el modelaje matemático que se haga para cuantificar las propiedades similares a que se refiere la definición mencionada.

Ahora bien, cuando se está capturando una imagen o cuando se le aplica alguna transformación a ésta es probable que se generen patrones ajenos a la escena respectiva; por eso se debe de tener presente la siguiente definición (Lira, 2001):

**Artefacto:** Patrón espacial o espectral presente en la imagen, cuya ocurrencia es azarosa y ajena a la escena respectiva.

Por lo que se puede decir que un artefacto sería un elemento que se introduce en la imagen digital, ya sea por mal funcionamiento del sensor o por la limitación de una transformación que se le aplique a la imagen o por error, el cual no tiene ninguna relación con los objetos del sistema físico que se desea estudiar. Por lo que para poder detectar un artefacto se debe tener conocimiento de la escena caracterizada por la imagen. Un artefacto no debe de ser confundido con ruido, donde el mecanismo físico es relativamente bien conocido y generado por un proceso estocástico.

Una vez que se tiene la imagen digital, se requiere separar los patrones de interés del resto de la imagen para poderlos estudiar, esto puede hacerse de manera real (se asignan píxeles de un patrón a una imagen intermedia, se tendrán tantas

imágenes como patrones se quieran separar) o virtual (se etiquetan píxeles según la clase, sin separarse de la imagen original).

Consideremos ahora un píxel  $p$  con coordenadas  $(i,j)$  como lo muestra la Figura 1.2, podemos ver que sus primeros próximos vecinos son aquellos píxeles con coordenadas:  $(i + 1,j)$ ,  $(i - 1,j)$ ,  $(i,j + 1)$ ,  $(i,j - 1)$ , estos píxeles se encuentran en las direcciones horizontales y verticales, las cuáles estarían especificadas por las direcciones 0, 2, 4 y 6 del código de Freeman; denotemos a este grupo de píxeles como  $N_4(p)$ . Los segundos próximos vecinos de  $p$  serían aquellos píxeles localizados en las diagonales principales cuyas coordenadas de estos vecinos son:  $(i + 1, j + 1)$ ,  $(i + 1, j - 1)$ ,  $(i - 1, j + 1)$ ,  $(i - 1, j - 1)$ , como se puede observar en la Figura 1.2, y sus respectivas direcciones están especificadas por las direcciones 1, 3, 5 y 7 del mismo código de Freeman; si a este grupo de píxeles lo denotamos como  $N_D(p)$ , entonces la unión de los grupos  $N_D(p)$  y  $N_4(p)$  forman los 8 primeros vecinos de  $p$  y quedarían designados como  $N_8(p)$ , es decir,  $N_8(p) = N_D(p) \cup N_4(p)$ .

Si se considera  $N_g$  al conjunto de valores posibles que puede asumir un píxel en una banda dada, entonces tendríamos establecidas las siguientes conectividades (Lira, 2001),

**Conectividad 4:** Dos píxeles  $p$  y  $q$  con valores en  $N_g$  tienen conectividad 4 si  $q$  pertenece al grupo  $N_4(p)$ .

**Conectividad 8:** Dos píxeles  $p$  y  $q$  con valores en  $N_g$  tienen conectividad 8 si  $q$  pertenece al grupo  $N_8(p)$ .

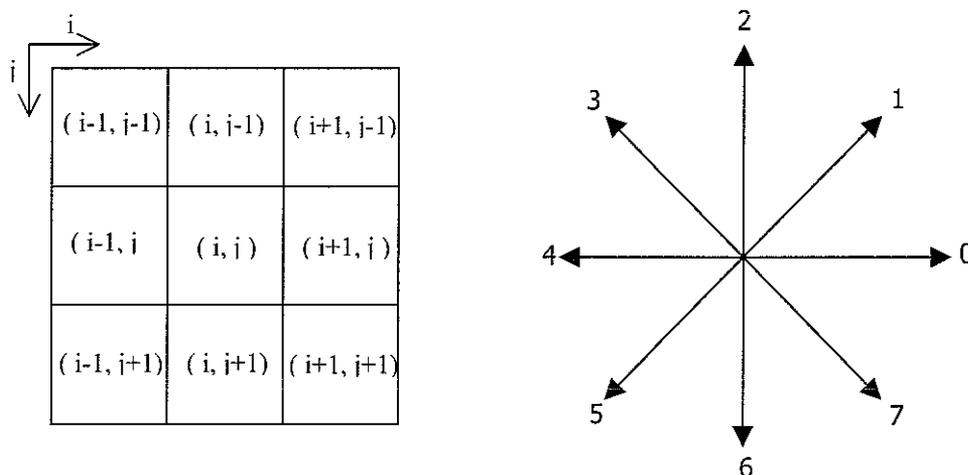


Figura 1.2. píxeles Vecinos y conectividad utilizando Código de Fremman.

Es así como el concepto de conectividad constituye una relación de vecindad espacial entre un píxel y sus próximos vecinos.

Hasta aquí se han revisado algunos de los conceptos básicos para comprender el procesamiento de una imagen digital, la cuál sería la representación de una escena bajo estudio, se debe de tener presente que su estructura y aspecto visual son importantes en cuanto a las conclusiones que pudieran derivarse acerca del comportamiento de la escena. No obstante se encontrará que llegan a existir ciertas limitaciones a dicha fidelidad, derivadas principalmente del mecanismo de digitización impuesto por el instrumento sensor y por fenómenos de interferencia que introducen ruido y degradan las medidas que componen la imagen digital resultante (Lira, 1995).

### 1.3. Imágenes de satélite.

Los satélites, de acuerdo a su trayectoria se clasifican en dos tipos: polares y geoestacionarios; los satélites que tienen órbitas polares se les conoce como satélites de percepción remota y los de trayectorias geoestacionarias como satélites del medio ambiente. En la Tabla 1.1 se muestran algunos de los principales satélites de percepción remota.

Es importante mencionar que algunos sistemas sensores similares a los satelitales han sido montados en plataformas aerotransportadas trayendo como consecuencia un incremento en la resolución espacial pero un decremento en el tamaño de la imagen resultante (Richards, 1986).

Estos sistemas representan la mayor fuente de datos de Percepción Remota y con mayor potencial de continuidad a lo largo del tiempo.

El sistema LANDSAT ha sido formado por 5 satélites, que fueron desarrollados por la NASA<sup>6</sup>, recibiendo inicialmente el nombre de *Earth Resources Technology Satellite - 1* (ERST - 1), que pasó a ser llamado LANDSAT en enero de 1975. Los Landsat 1 y 2 cargaron a bordo dos sistemas sensores con la misma resolución espacial, pero con diferentes concepciones de generación de imágenes: el sistema RBV, con registro instantáneo de toda la escena y el sistema MSS, con observación y registro del terreno por barrido de líneas.

---

<sup>6</sup> NASA es el acrónimo de National Aeronautics and Space Administration

**Tabla 1.1 Algunos sensores y plataformas empleados en percepción remota.**

Plataforma Dato	Landsat 4,5	Spot 1,2	Seasat	ERS-1	Radarsat
Fecha de lanzamiento	julio, 1982 y marzo, 1984	noviembre, 1985	junio, 1978	mayo, 1991	noviembre, 1995
Altura promedio sobre la tierra	700 km	822 km	790 km	785 km	798 km
Período de la órbita	90 minutos	101 minutos	100 minutos	100 minutos	100.7 minutos
Período de cobertura	16 días	26 días		3 días	24 días
Tamaño del elemento de resolución	30x30 m <sup>2</sup> y 120x120 m <sup>2</sup> en la banda 6	20x20 m <sup>2</sup> y 10x10 m <sup>2</sup> en la banda 4	25x25 m <sup>2</sup>	30x30 m <sup>2</sup>	25x25 m <sup>2</sup>
Tamaño de la imagen	185x185 km <sup>2</sup>	60x60 km <sup>2</sup>	100x100 km <sup>2</sup>	80x80 km <sup>2</sup>	130x130 km <sup>2</sup>
Bandas espectrales	1)0.45-0.52 μm 2)0.52-0.60 3)0.63-0.69 4)0.76-0.90 5)1.55-1.75 6)10.4-12.5 7)2.08-2.35	1)0.50-0.59μm 2)0.61-0.69 3)0.79-0.90 4)0.51-0.73	25 cm (banda L)	5.7 cm (banda C)	5.6 cm (banda C)

Los satélites de esta tabla tienen órbita polar. El Seasat está fuera de operación, sin embargo, el legado de imágenes que dejó es de considerable importancia. Los Spot 1 y 2 son franceses, ERS-1 es un satélite lanzado por la Agencia Espacial Europea, el Radarsat es canadiense y el resto es de los E U A.

Los dos sistemas se proponían la adquisición de datos multiespectrales, más el desempeño del sistema MSS, en términos de fidelidad radiométrica, hizo que el tercer satélite de la serie tuviese su sistema RBV modificado, de modo que generara datos con mejor resolución espacial en una única banda del espectro. Por otro lado fue acrecentada una banda espectral al sistema MSS, para operar en la región del infrarrojo termal. A partir del Landsat 4 y 5, al contrario del sensor RBV, la carga útil del satélite pasó a contar con el sensor TM, operando en 7 bandas espectrales. Ese sensor conceptualmente es semejante al MSS ya que es un sistema de barrido de línea, además incorpora una serie de perfeccionamientos en sus componentes ópticos y electrónicos.

### Generador de imágenes MSS.

MSS (Multispectral Scanner). Actualmente ya se encuentra fuera de operación, era un sistema sensor que permitía el registro de líneas de terreno en una faja de 185 km, perpendicular a la órbita del satélite. El barrido del terreno era realizado con auxilio de un espejo que oscilaba perpendicularmente al desplazamiento del satélite. Durante la oscilación del espejo, la imagen del terreno, a lo largo de la faja, era focalizada sobre una matriz de detectores. A cada oscilación del espejo, el satélite se desplazaba a lo largo de la órbita para proporcionar la

*observación continua del terreno. Entre tanto, el movimiento de rotación de la Tierra provocaba un pequeño desplazamiento del punto inicial de barrido para oeste a cada oscilación del espejo.*

#### **Generador de imágenes TM.**

TM (Thematic Mapper). Es un sistema avanzado de barrido multispectral concebido para proporcionar: resolución espacial más fina, mejor discriminación espectral entre objetos de la superficie terrestre, mayor fidelidad geométrica y mejor precisión radiométrica en relación al sensor MSS. La energía proveniente de la escena llega al espejo de barrido que oscila perpendicularmente a la dirección de movimiento del satélite en sentido aproximadamente Este-Oeste y Oeste-Este. La señal pasa por un telescopio y un conjunto de espejos, cuya función principal es enfocar la señal colectada por el espejo de barrido. De esa manera, la señal detectada en cada matriz de detectores es transferida por un amplificador y convertida en señal digital a través de un sistema analógico/digital (A/D). La salida de datos es transmitida vía telemetría.

#### **SPOT.**

El sistema SPOT es parte del programa espacial francés semejante al programa Landsat, que fue concebido por el Centre National d'Etudes Spatiales (CNES) y lleva a bordo dos sensores de alta resolución (HRV – HAUT Resolution Visible). Estos sensores fueron concebidos para operar a dos diferentes modos. El modo multispectral permite la adquisición de datos en tres bandas del espectro electromagnético con una resolución espacial de 20 metros. El modo pancromático con una resolución espacial de 10 metros. Una de las características sobresalientes de los instrumentos a bordo del SPOT es la posibilidad de observación 'apuntando direccionalmente'. El sensor podrá ser direccionado de modo que observe escenas laterales a la órbita en que se encuentra el satélite en un momento dado, esta posibilidad de observación aumenta los medios de obtener un aumento en el recubrimiento repetitivo de determinadas áreas y otra de las ventajas es la posibilidad de obtener pares estereoscópicos de determinadas áreas

La luz proveniente de la escena se refleja en un espejo plano, que puede ser controlado a partir de las estaciones terrenas variando en ángulo de +/- 0.6 hasta 27° en relación al eje vertical. La energía que llega al espejo plano es focalizada sobre una matriz que consiste de 6000 detectores ordenados linealmente, conocidos como sistema de barrido electrónico. Este sistema permite el registro instantáneo de una línea completa en el terreno, perpendicular a la dirección de movimiento del satélite en su órbita (Instituto Nacionade Pesquisas Espaciais, 1994).

Gracias a los avances tecnológicos logrados en la última década, las imágenes que se generan con satélites son de alta calidad, de amplia visión sinóptica, de muy buena resolución espacial, cubriendo la parte óptica del espectro electromagnético y con una frecuencia de adquisición que va desde media hora hasta 26 días.

Las ventajas que presentan las imágenes de satélite con respecto a una fotografía aérea convencional son entre otras: el costo por km<sup>2</sup> es inferior, su carácter digital y multiespectral permite tener un registro permanente en computadora tanto de los datos originales como de los transformados, rapidez de análisis y facilidad para aplicar operaciones que no se pueden realizar sobre una fotografía tal como la descomposición en componentes principales y la transformada de Fourier (Chavira, 1996).

#### 1.4. Imágenes de Radar (SAR).

Las imágenes de satélite y aéreas han tenido en los últimos años una gran importancia debido a que han facilitado los estudios del medio ambiente y el monitoreo de los recursos de la Tierra.

En las dos últimas décadas, el avance de la tecnología en radares de apertura sintética SAR<sup>7</sup> ha dado origen a los sensores remotos con capacidades diferentes a los ya existentes; éste sensor de microondas (Lillesand y Kiefer, 1987) tiene como características penetrar nubes, polvo, bruma y tiene mayor capacidad para penetrar vegetación que las ondas de rango óptico. Este tipo de sensor se considera que es independiente de las condiciones climatológicas puesto que puede penetrar lluvia y neblina, es para toda época del año y también puede operar durante el día o la noche porque él mismo suministra su propia iluminación.

##### ERS-1.

Fue construido por la Agencia Espacial Europea (ESA) con una misión nominal de dos años, los objetivos son focalizados principalmente para estudios oceánicos y de glaciares, en varias áreas de ciencias naturales. Entre los varios sensores a bordo del satélite tenemos el AMI (Active Microwave Instruments), constituido por un radar de Abertura Sintética (SAR) y un dispersómetro<sup>8</sup>. Las imágenes adquiridas por el SAR, suministran datos de una franja de 100 x 100 km, con una resolución de 30 metros. La operación del SAR en el modo Imagen produce una tasa de datos muy alta, haciendo que las imágenes sólo puedan ser generadas en zonas equipadas con estaciones receptoras. La superficie terrestre podrá ser enteramente cubierta y registrada en ciclos de 35 días (Instituto Nacionade Pesquisas Espaciais, 1994).

Como se observa, las imágenes SAR tienen un gran futuro; otra de las características que tienen estas imágenes, por lo cual son muy utilizadas, es su riqueza en información de texturas.

---

<sup>7</sup> SAR es el acrónimo de Synthetic Aperture Radar

<sup>8</sup> Dispersómetro es un aparato para medición de vientos.

El campo de aplicaciones de las imágenes SAR es muy vasto y continúa en constante crecimiento. Estas imágenes tienen la peculiaridad de que los rasgos geomorfológicos de un terreno son realzados, por lo que en el área de la geofísica son de gran utilidad. En los últimos años ha crecido el interés de aplicar este tipo de imágenes en la cartografía y la valoración de recursos forestales, identificación de claros por talas y detección de cambios en uso de la tierra. En la agricultura, para la identificación de tipos de cultivos, predicción e inventario de cosechas, estimación de la humedad del suelo, densidad y cobertura de la vegetación. En aplicaciones hidrológicas son empleadas para crear los mapas de la red de drenaje en una zona y determinar sus características geométricas, disponibilidad de agua superficial, cobertura de nieve y su potencial acuífero. En el monitoreo oceanográfico de fenómenos tales como olas, corrientes y remolinos. Existe toda una línea de investigación en la aplicación de imágenes de radar que ha alcanzado a campos como la arqueología. Todo esto lo podemos observar en la Tabla 1.2, la cual nos muestra algunas de las aplicaciones de imágenes digitales generadas por sensores satelitarios.

Tabla 1.2 Aplicaciones regionales de la percepción remota en relación a los indicadores relevantes en la escena y el sensor satelitario requerido.

Aplicación Regional	Indicadores relevantes	Sensor satelitario o aerotransportado
Producción de información geográfica y cartográfica	Topoformas, modelos numéricos del terreno, unidades integradas del terreno.	Landsat 4 y 5 SPOT
Prospección minera y petrolera	Geoformas, lineamientos, patrones de textura, litologías, unidades integradas del terreno, anomalías magnéticas y gravimétricas, anomalías en la distribución de la vegetación.	Landsat 4 y 5 SPOT Sensores magnéticos gravimétricos aerotransportados
Geohidrología	Patrones de textura de drenaje, geoformas, unidades integradas del terreno, litologías, anomalías en la distribución de la vegetación, anomalías magnéticas y gravimétricas, topoformas, lineamientos, biomasa de la vegetación.	Landsat 4 y 5 SPOT Sensores magnéticos gravimétricos aerotransportados
Geotermia	Distribución de temperaturas superficiales, distribución de capacidad térmica del suelo, extensión y localización de alteración hidrotermal, anomalías magnéticas y gravimétricas.	Mapeador de capacidad térmica Landsat 4 y 5 Sensores magnéticos gravimétricos aerotransportados
Silvicultura y agricultura	Área foliar y biomasa de la vegetación, unidades integradas del terreno, anomalías en la distribución de la vegetación, litologías.	Landsat 4 y 5 SPOT
Meteorología	Patrón de nubes, patrón de vientos.	Nimbus 7 GOES 6
Oceanografía y estudios	Distribución de temperaturas del océano, concentración de clorofila, patrón de corrientes marinas.	Landsat 4 y 5 Nimbus 7 Radarsat

TESIS CON  
FALLA DE ORIGEN



# CAPÍTULO DOS

## DESERTIFICACIÓN.

El fenómeno conocido como desertificación en años recientes ha recibido una amplia atención, lo cual se afirma por medio de la creación de la Asamblea de las Naciones Unidas sobre Desertificación (UNCOD)<sup>1</sup> en Nairobi en 1977, principalmente como resultado del impacto de la sequía extendida en Sahel al Occidente de África, cerca de los años setenta. Esta sequía condujo a la pérdida de vidas humanas y de ganado, así como a un amplio deterioro del ambiente. Ahora bien, aunque muchos artículos recientes, documentos y reportes provenientes de diversos países comienzan con algún comentario acerca del papel de la sequía de Sahel en el crecimiento del interés en el problema de la desertificación, quedan significantes desacuerdos, dentro y entre las diferentes disciplinas (también como entre países), en cómo y qué constituye la desertificación. La sequía de Sahel no fue la primera manifestación del fenómeno de la desertificación ni la razón para que los científicos se interesaran en ello. De hecho, un científico francés, A. Aubreville popularizó el término 'desertificación' en su informe en 1949, y otros como Le Houerou (1962) han discutido el fenómeno desde finales de los años cincuenta. La asamblea hecha en Nairobi (1977) sirve para llamar la atención hacia dicho fenómeno (Glantz y Orlovsky, 1986).

Mientras tanto en México, la Secretaría de Relaciones Exteriores (SRE) fue comisionada por el ejecutivo a principios de 1977 para construir un Grupo

---

<sup>1</sup> UNCOD es el acrónimo de United Nations Conference on Desertification

Intersecretaral para Asuntos Internacionales sobre Desertificación (GIAID), donde participaron las Secretarías de Estado, así como instituciones académicas y de investigación relacionados con el problema (Medellín- Leal, 1978). Como parte de las principales actividades relacionadas por el GIAID, se organizó una Reunión Nacional sobre Desertificación (RENADES) que tuvo como objetivos analizar los documentos preliminares sobre el problema, preparados por expertos de Naciones Unidas, y elaborar un plan para combatir la desertificación, con base en la problemática nacional, que incluiría las recomendaciones que la Delegación Mexicana llevaría a la UNCOD.

Dentro de los distintos tópicos analizados en la UNCOD una parte de la atención fue centrada en el uso de sensores remotos para la vigilancia continua del fenómeno de la desertificación (De la Torre, 1984).

Durante los últimos cuarenta años, en México se han registrado cambios drásticos, al mantener un crecimiento de la población, una urbanización y una industrialización aceleradas y al modificar las políticas relativas al campo, provocando alteraciones irreversibles sobre superficies que anteriormente conformaban los ecosistemas terrestres del país.

La conservación de los suelos depende, en primer término, de que sean utilizados de acuerdo con sus aptitudes naturales, y segundo, que su manejo sea técnicamente adecuado. De otra forma, se corre el riesgo de generar efectos físicos, químicos y biológicos que traen como consecuencia la pérdida de la fertilidad del suelo, esto es, la pérdida de su humus y de las sustancias que lo hacen productivo.

La erosión es una de las principales causas de la desertificación en el país y constituye uno de los problemas más severos de los recursos renovables de México. Los diversos procesos que propician la degradación de la tierra afectan en distintos grados a 65% del territorio nacional. En tales procesos sobresalen los de erosión eólica e hídrica que afectan 15% y 37%, respectivamente de la superficie del país, así como el proceso de degradación biológica<sup>2</sup>, química y física los cuales afectan 13% del territorio nacional (INEGI, 1999).

A partir del fenómeno de la desertificación y del análisis sobre el problema que puede generarse ante un continuo proceso de este fenómeno, es como surge el interés por encontrar medios para monitorear y controlar dicho fenómeno, así como para tener herramientas que sirvan de solución al fenómeno de la desertificación o prevenirlo, con base en todo esto se plantea y propone en la presente tesis un modelo matemático que caracterice el fenómeno de la desertificación, desde el punto de vista de la percepción remota, y a la vez ayude a su prevención.

---

<sup>2</sup> Degradación biológica: aumento de la mineralización de la materia orgánica del suelo, debido, entre otros factores, a la remoción del manto vegetal y al cultivo excesivo

## 2.1. ¿Qué es la Desertificación?

El término ‘desertificación’ ha sido motivo de muchas controversias, ya que este término ha eludido una definición propia debido a que es un proceso que no se ha entendido bien y también a que diversos autores han utilizado la definición de maneras diferentes.

Algunos investigadores consideran que la desertificación es un proceso de cambio, mientras que otros la ven como el resultado final de un proceso de cambio. La desertificación como un proceso ha sido generalmente vista como una serie de cambios secuenciales en la productividad biológica hasta convertirse en ecosistemas áridos, semi-áridos y sub-húmedos. La desertificación como un evento es la creación de condiciones desérticas como el resultado final de un proceso de cambio (Glantz y Orlovsky, 1986).

La desertificación no es simplemente el proceso de un área que comienza a ser árida, y esto no es solamente causado por la sequía. De hecho, la desertificación es usualmente definida como un proceso que ocurre hasta que la tierra está realmente árida o semi-árida. El factor crucial es una decadencia en la productividad biológica de la tierra, es decir, la cantidad de vegetación que crece, como también la vida animal soportada por las plantas (EROS, 1999).

A continuación se proporciona una serie de definiciones que se han hecho para describir el fenómeno de la desertificación:

- *Desertificación* es la disminución o destrucción del potencial biológico de la tierra, y puede guiar finalmente a condiciones desérticas (UNCOD, 1977a).
- *Desertificación* puede también ser descrita como un proceso de empobrecimiento de ecosistemas áridos, semi-áridos y algunos sub-húmedos por los impactos combinados de las actividades del hombre y la sequía (Dregne, 1976).
- *Desertificación* también es definida como un proceso continuo que reduce la productividad biológica, con una reducción consecuentemente en la vegetación, en la capacidad de sostenimiento de la tierra para el ganado, en los campos de cultivo y donde la actividad antropogénica ocasiona una intensificación o extensión de las condiciones de tipo desérticas (UNCOD, 1977b).
- *Desertificación* (desertización) fue definida como la extensión de condiciones de desierto en áreas áridas o semi-áridas debido a la influencia del hombre o a cambios climáticos (Rapp, 1974).

■ *Desertificación* ha sido definida como una reducción en la capacidad del suelo para producir en términos de cantidad, calidad, bienes y servicios, donde algunos otros conceptos son importantes para esta definición:

- Sustentabilidad o habilidad de la tierra para producir indefinidamente;
- Elasticidad o resistencia de la calidad de la tierra a la degradación;
- Capacidad de soporte o el número de gente y animales que la tierra pueda normalmente soportar sin que sea significativamente alterada (CIESIN, 1996).

Está implícitamente entendido que la desertificación trae como consecuencia condiciones desérticas duraderas y posiblemente irreversibles. La ‘disminución de productividad’ es una clave del proceso incluida implícitamente o explícitamente en todas las definiciones anteriores (Hellden, 1988).

Después de acaloradas polémicas y controversias entre numerosos científicos que participaron en las reuniones preparatorias a la UNCOD, los esfuerzos se consumaron en dos definiciones:

“Se usa ‘*desertización*’ cuando uno se refiere al acrecentamiento de los desiertos por causas naturales, principalmente motivados por cambios climáticos a muy largo plazo y se adopta ‘*desertificación*’ cuando uno se refiere a la disminución o la destrucción del potencial biológico de la tierra que puede desembocar en definitiva en condiciones de tipo desérticas” (De la Torre, 1984).

## 2.2. ¿Por qué ocurre la desertificación?

Algunos investigadores consideran que el clima es quien contribuye principalmente al proceso de la desertificación, con factores humanos representando un papel relativamente menor. Otros investigadores opinan de manera contraria respecto a estos dos factores. Un tercer grupo culpa al clima y al hombre más o menos igualmente. Cada uno de estos puntos de vista pueden ser mostrados como válidos por lo menos a un nivel local.

### *Clima*

En relación al clima se debe tener presente la variabilidad de climas, el cambio climático o la aridez. La variabilidad del clima parece referirse a las fluctuaciones naturales que figuran en representaciones estadísticas del estado de la atmósfera para un período designado de tiempo, usualmente en el orden de meses a décadas. Las fluctuaciones pueden ocurrir en todas o cualquiera de las variables atmosféricas (como la precipitación, temperatura, velocidad y dirección del viento, evaporación, entre otras). Un resultado de estas fluctuaciones puede llegar a ser la

alteración de un ecosistema y esto, eventualmente, afecta las actividades sociales que han sido desarrolladas para explotar la productividad de dicho ecosistema.

Es importante notar que durante las estaciones de sequía anual las características de la atmósfera en una zona árida o semi-árida son como las de una región desértica (baja precipitación, alta evaporación, alta radiación solar, entre otras) y si el uso inapropiado de la tierra ocurre durante este período, da como resultado la degradación. En consecuencia, las fluctuaciones en términos cortos sobre los factores climáticos, y también sobre período de estaciones de sequía, cuando se combinan con prácticas inapropiadas del uso de suelo, pueden dar la apariencia como de un cambio de clima cuando puede no haber ocurrido del todo.

El cambio de clima se refiere a cambios en grandes términos relativamente, que aparece en las estadísticas que representan el estado promedio de las condiciones atmosféricas. Típicamente, la desertificación es vista como un resultado de cada alteración natural en un régimen climático. Los períodos de aridez también han sido citados como una causa mayor de la desertificación, sin embargo, durante cada período extenso de sequía la desertificación se hace relativamente más severa, se va extendiendo y es más visible, así como la relación de ocurrencia se incrementa agudamente. Puesto que la probabilidad de aridez se incrementa como un cambio de lo húmedo a las regiones más áridas, es así como también se hace propensa la región a la desertificación. La forma de la tierra, los suelos y la vegetación son frecuentemente transformados durante cada período de aridez.

### *Actividades humanas*

El cultivo, la ganadería y la recolección de madera, así como el uso de tecnología, son actividades que han sido citadas en las definiciones como la mayor causa, y contribución, para el proceso de la desertificación en zonas áridas, semi-áridas y sub-húmedas. Las prácticas del cultivo que pueden contribuir a la desertificación incluyen prácticas de limpieza de la tierra, cultivo de regiones con climas extremos, cultivo en suelos pobres y técnicas de cultivo no apropiadas como la reducción del tiempo sin cultivar, labranza inadecuada, drenaje y uso del agua.

El uso de terrenos puede contribuir a la desertificación al utilizarlos excesivamente con un gran número de cabezas de ganado de acuerdo a las condiciones existentes (contribuyen acabando con el pasto o pisoteándolo) y la concentración de ganado alrededor de los establecimientos humanos y puntos acuíferos. Políticas gubernamentales en apoyo a los ganaderos también pueden de manera indirecta contribuir a la desertificación.

La recolección de madera, por sí misma o en combinación con las prácticas de cultivo inapropiadas o deforestación, origina condiciones que exponen la tierra a factores meteorológicos que pueden llegar a no ser benignos (como el viento, la

evaporación, precipitación, radiación solar sobre suelos descubiertos), por lo que se estaría contribuyendo a la desertificación.

El uso de la tecnología en ambientes áridos, semi-áridos y sub-húmedos es el resultado de la implementación de manufactura por tener un mejor desarrollo económico. Es así como la construcción de pozos profundos, esquemas de irrigación y planes de cosechas puede incrementar los riesgos hacia un proceso de desertificación de una cierta área. Ha sido demostrado que la desertificación puede resultar también de la construcción de carreteras, de industrias, inspecciones geológicas, extracción de metales, irrigación y drenaje, así como transporte (Roanov, 1977).

En resumen, muchos investigadores aceptan que ambos factores, tanto el clima como el hombre, están inmersos en el proceso de la desertificación (Glantz y Orlovsky, 1986). Debido a lo anterior, la fertilidad del suelo es una propiedad que debe registrarse de manera continua, debido a los múltiples factores que intervienen en su variabilidad estacional, entre los que se puede citar al tipo de cultivo, aplicación de materia orgánica y/o fertilizante, labores mecánicas, presencia de erosión, precipitación, entre otros (SEMARNAT e INEGI, 1999).

### 2.3. Indicadores del proceso de la Desertificación.

La importancia de evaluar y monitorear los estados y el proceso de la desertificación a niveles locales o más altos fue reconocida bajo el Plan de Acción para Combatir la Desertificación (PACD<sup>3</sup>) y seguido en los años ochenta por la Organización Alimenticia y de Agricultura (FAO<sup>4</sup>) y el Programa Ambiental de las Naciones Unidas (UNEP<sup>5</sup>), quien desarrolló una metodología provisional para la evaluación y proyección de la desertificación (PMAMD<sup>6</sup>). La metodología ha sido examinada y adaptada a través de dos proyectos pilotos (Krugmann, 1996).

Ciertos estudios sobre el uso de indicadores y métodos para la evaluación, monitoreo y mapeo de la desertificación a niveles locales o nacionales han sido propuestos por la FAO/UNEP, los estudios han utilizado una combinación de técnicas de percepción remota e inspección de campo para coleccionar datos acerca de ciertos indicadores de la desertificación.

La Tabla 2.1 muestra una lista de factores físicos, biológicos y socioeconómicos de la desertificación a partir de un conjunto de indicadores propuestos por la metodología provisional de la FAO/UNEP (Krugmann, 1996).

---

<sup>3</sup> PACD es el acrónimo de Plan of Action to Combat Desertification.

<sup>4</sup> FAO es el acrónimo de Food and Agriculture Organization

<sup>5</sup> UNEP es el acrónimo de United Nations Environment Programme

<sup>6</sup> PMAMD es el acrónimo de Provisional Methodology for Assessment and Mapping of Desertification.

#### 2.4. Percepción Remota y Desertificación.

El reciente desarrollo de satélites para la observación de los recursos naturales prevé el inicio de una nueva era en el tratamiento de datos geográficos. Walker y Robinove (Walker y Robinove, 1981) sugieren que la investigación sobre desertificación con sensores remotos puede ser dividida en métodos para localizar, evaluar y monitorear el cambio que provoca este fenómeno. Los métodos para localizar áreas afectadas implican no sólo la identificación de las ya desertificadas, sino también aquellas con un alto riesgo a deteriorarse en el futuro. Los métodos de evaluación son aquellos que implican la identificación o medición de algunos atributos del terreno, como son la cantidad de vegetación, el tipo de suelo y patrones de uso del suelo, entre otros; todo esto en un intento por determinar la naturaleza y susceptibilidad del ecosistema al cambio. Los métodos de monitoreo de la desertificación se refieren a la detección y medición del cambio de las características del terreno. La detección del cambio en un período de tiempo puede establecerse como la diferencia entre dos valores de una característica cuantificable.

Algunas veces es mejor medir la tasa de cambio entre dos estados del sistema en un período de tiempo que intentar describir el estado absoluto del sistema en un momento dado. Esto debido a que se desconocen las condiciones naturales originales para determinar la desviación del estado actual con respecto a ese nivel de referencia (Walker y Robinove, 1981).

La UNEP en colaboración con la FAO se abocaron al desarrollo de una metodología para evaluar y cartografiar la desertificación, tanto en sus causas como en su dinámica, de acuerdo con la responsabilidad que asumió después de la UNCOD en 1977. De manera general la metodología de la UNEP se basa en la evaluación de tres criterios: estado actual, velocidad y riesgo. Para cada uno de los criterios se consideran cuatro clases de desertificación: inexistente, ligera, moderada y severa. El estado actual se refiere al conjunto de condiciones observadas en el paisaje para un instante de tiempo, que bien pudiera ser el resultado de un cambio perceptible respecto a un punto de referencia, tal como las condiciones naturales originales. La velocidad de desertificación es la rapidez con la cual los procesos de desertificación avanzan en una zona dada por unidad de tiempo. Se consideran siete procesos como los responsables de la desertificación (degradación de la cubierta vegetal, erosión hídrica, erosión eólica, salinización, reducción de la materia orgánica del suelo, encostramiento y compactación del suelo, y la acumulación de sustancias tóxicas para las plantas o los animales). El riesgo de desertificación se considera como la susceptibilidad a la desertificación de un terreno o una predicción a futuro de los problemas de desertificación (Ortiz y Anaya, 1982).

Tabla 2.1 Factores para evaluar la desertificación.

Tipo y subtipo de indicador		Factores
Físico	Clima	<ul style="list-style-type: none"> <li>a. Precipitación</li> <li>b. Temperatura</li> <li>c. Velocidad, dirección y frecuencia del viento</li> <li>d. Potencial de erosión por lluvia</li> <li>e. Duración de luz solar</li> <li>f. Potencial de evapotranspiración</li> <li>g. Tormentas de arena y polvo</li> <li>h. Vórtices</li> </ul>
	Suelos	<ul style="list-style-type: none"> <li>a. Estado de la superficie (rocosidad)</li> <li>b. Textura</li> <li>c. Fertilidad (materia orgánica)</li> <li>d. Estructura</li> <li>e. Permeabilidad</li> <li>f. Potencial de erosión</li> <li>g. Alcalinización/Salinización</li> <li>h. Unidad de trazo del suelo</li> </ul>
	Topografía	<ul style="list-style-type: none"> <li>a. Pendientes</li> </ul>
Biológico	Vegetación	<ul style="list-style-type: none"> <li>a. Cobertura de hierba y árboles</li> <li>b. Producción de biomasa Hierba / madera</li> <li>c. Composición de plantas y especies claves</li> <li>d. Potencial de producción herbácea</li> <li>e. Unidad de trazo de vegetación</li> </ul>
	Animales	<ul style="list-style-type: none"> <li>a. Distribución y estimación de población animal</li> <li>b. Composición de rebaños</li> <li>c. Consumo herbáceo</li> </ul>
Socioeconómicos	Uso de tierra y agua	<ul style="list-style-type: none"> <li>a. Uso de tierra</li> <li>b. Consumo de combustible (madera)</li> <li>c. Requerimientos y disponibilidad de agua</li> </ul>
	Patrones de poblados	<ul style="list-style-type: none"> <li>a. Poblados</li> <li>b. Infraestructura</li> </ul>
	Parámetros humano-biológicos	<ul style="list-style-type: none"> <li>a. Estructura de poblados y relación de crecimiento</li> <li>b. Medición del estado nutricional</li> <li>c. Hábitos alimenticios</li> </ul>
	Parámetros de procesos sociales	<ul style="list-style-type: none"> <li>a. Conflictos</li> <li>b. Migración</li> <li>c. Percepción del ambiente</li> </ul>

**TESIS CON  
FALLA DE ORIGEN**

Gilbert Long (Ortiz y Anaya, 1982) desarrolló un esquema sobre los niveles de percepción ecológica que ha servido de base para la interpretación y comunicación de los resultados en estudios ecológicos. Ha distinguido cinco niveles que van desde 'zona ecológica', donde se usan datos obtenidos de sensores espaciales, como el satélite Landsat, hasta el de estación 'experimental', donde se usan datos derivados de muestreos dentro de la estación terrestre. Este esquema tiene particular importancia cuando se hacen estudios con datos obtenidos en un nivel y después se pretende sean verificados en otro nivel.

Para algunas aplicaciones de la percepción remota el problema de extender la información desde una plataforma terrestre hasta una espacial ha sido superado sin muchas dificultades. Sin embargo, para el caso de la desertificación es necesario medir atributos espaciales y espectrales. La desertificación no está relacionada unívocamente con la respuesta espectral del terreno. Por lo que una estrategia más viable consiste en el uso de indicadores discernibles para detectar cambios en la cobertura vegetal inducidos por la desertificación.

Han sido propuestos diversos indicadores como la covarianza entre dos bandas de la imagen, la correlación entre bandas, la varianza del primer eigenvalor (Coiner, 1981), así como el albedo (Robinove et al., 1981), que se define como la reflectividad del suelo, para generar mapas de diferencias en imágenes y con ello monitorear cambios en la calidad del medio árido y semi-árido.

Walker y Robinove hicieron un análisis de 118 artículos relacionados con el estudio de la desertificación mediante sensores remotos. Ellos discuten la conveniencia y el alcance de los métodos de percepción remota, así como el tipo de indicadores considerados para analizar el seguimiento sistemático de la desertificación. Encontraron que las técnicas de percepción remota todavía no han alcanzado un uso operacional en el estudio de la desertificación, aunque éstas representan un valioso recurso que pueden contribuir significativamente. Finalmente, ellos sugieren que la selección del método para monitorear la desertificación depende de la precisión requerida, la eficiencia con la cuál los datos pueden ser capturados y analizados, el horizonte de tiempo dentro del cuál las respuestas son necesarias, los medios disponibles para efectuar el monitoreo y los recursos disponibles para realizar la tarea del monitoreo dentro de un intervalo de tiempo (De la Torre, 1984).

Pickup y Chewings (Pickup y Chewings, 1988) proponen un modelo para pronosticar patrones a gran escala de la erosión y deposición del suelo, a partir de datos Landsat MSS, en regiones áridas. El modelo utilizado para pronosticar cambios es un proceso autoregresivo de primer orden, el cual puede producir cambios en la media, la varianza y la autocorrelación espacial.

Metternicht y Fermont (Metternicht y Fermont, 1997) desarrollaron un modelo espectral para la identificación de rasgos sobre degradación del suelo

relacionados con el proceso de la erosión. Utilizaron un análisis espectral lineal, donde por medio de la extrapolación se observa que la degradación del suelo está correlacionada con superficies espectralmente distinguibles, teniéndose así una optimización del modelo. Tansey y Andrew (Tansey y Andrew, 1998) utilizaron sensores SAR<sup>7</sup> para monitorear ciertas superficies de suelo árido. La humedad del suelo y su textura, la rugosidad de la superficie y datos sobre la vegetación fueron observados junto con datos climáticos desde una estación automática de monitoreo de clima. Todos estos datos se utilizaron para obtener una aproximación de un modelo de ecuación integral, dando como resultados buenas correlaciones entre ellos.

Si se imagina una zona con alta densidad de vegetación, uno puede observar como si se estuviera en el espacio que el paisaje muestra ciertas características, donde debido a la cantidad de vegetación presente en esa región no se puede observar tan fácilmente el suelo que se encuentra por debajo de la vegetación. Ahora bien, si se define el proceso de desertificación como un proceso continuo que reduce la productividad biológica, con una reducción consecuentemente en la vegetación, podemos imaginar que si en la zona, anteriormente descrita con una alta densidad de vegetación, se tuviera presente el proceso de desertificación como resultado se reduciría gradualmente la vegetación, provocando un cambio en el paisaje. Se podría observar como en ciertas áreas estaría quedando expuesto el suelo, esto se reflejaría en un cambio de textura y a la vez en un cambio en la reflectividad de la radiación sobre esa zona, ya que el suelo posee mayor reflectividad de la radiación que la vegetación. Se puede ver que el proceso de desertificación implica cambios en el paisaje y estos cambios se pueden cuantificar, como en este ejemplo a través de la textura, de la reflectividad o albedo y la densidad o vigor de la vegetación presente en una región. Se tienen en la actualidad algunos antecedentes sobre el uso de la percepción remota para evaluar el proceso de desertificación, en la presente tesis, en capítulos posteriores, se plantea un modelo matemático del proceso de la desertificación empleando la percepción remota y variables como el albedo, la textura y un índice de vigor de vegetación y humedad del terreno, con la información que se requiere para analizar y estudiar este proceso.

---

<sup>7</sup> SAR es el acrónimo de Synthetic Aperture Radar.

# CAPÍTULO TRES

## EVALUACIÓN DE TEXTURAS.

En este capítulo antes de plantear una evaluación de texturas, se profundiza un poco sobre el proceso de filtrado a una imagen por medio de varios filtros. Para la obtención de una imagen de texturas se manejan dos métodos, un método es utilizando una imagen de radar y el otro es utilizando una imagen multiespectral. Para el primer caso, primero se requiere de filtrar la imagen debido a la presencia de ruido. El proceso de filtrado se realizó empleando varios algoritmos, una vez realizado el filtraje se hace una comparación entre los diferentes resultados obtenidos y, por medio de diferentes descriptores sobre la calidad de la imagen, se selecciona la imagen que presenta el filtrado más óptimo y posteriormente se procede a determinar la textura. Así como se plantean varios algoritmos de filtrado y se selecciona el que presenta un mejor resultado, también se plantean dos métodos para determinar texturas y después de analizarlos cualitativamente se selecciona el de mejores resultados.

Como se sabe hasta ahora, una imagen digital es una representación de una escena bajo estudio, como tal su estructura y aspecto visual son importantes en cuanto a las conclusiones que pudieran derivarse acerca del comportamiento de la escena. Sin embargo, existen limitaciones a la fidelidad con la que la imagen digital caracteriza a dicha escena, provenientes primordialmente del mecanismo de digitización impuesto por el instrumento sensor y por fenómenos de interferencia que introducen ruido y degradan las medidas que componen la imagen digital resultante (Lira, 2001).

Por lo que en la captura y registro de una imagen multiespectral de una escena dada existen siempre fenómenos o medios de interferencia que degradan la información contenida en la imagen digital (Lira, 1987). De ahí que antes de hacer cualquier conclusión con respecto a lo que representan ciertos patrones en la imagen, es necesario aplicarle cierto procesamiento a la imagen digital para realzar los elementos o características de interés en la misma, así como cuantificar su calidad.

### 3.1. Mecanismos de degradación: Ruido

Cualquier imagen registrada a través de un dispositivo de medición ha sido formada en la presencia de *fuentes de degradación*. En algunos casos, sin embargo, es tan pequeña que resulta despreciable, mientras que en otros la degradación altera la información al grado que la imagen no es apta para una interpretación visual, ni para análisis digital ulterior. En una degradación lo que se tiene presente es un fenómeno físico que interfiere al proceso de generación de una imagen. Por lo que, en imágenes ópticas de satélites, es posible deducir que las fuentes de degradación se encuentren presentes en la atmósfera o en el medio ambiente entre el sensor y la escena, como un efecto de los instrumentos del sistema sensor (detector), en la escena misma, o como una combinación de ambos. En la figura 3.1 se muestra un esquema de la degradación.

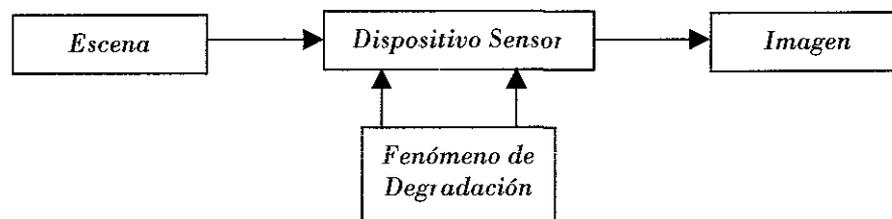


Fig. 3.1 Esquema de fuentes de degradación.

El *ruido* es un patrón espacial que no tiene relación con la escena, cuya aparición es el resultado de algún proceso estocástico<sup>1</sup>; su comportamiento y propiedades estadísticas se pueden obtener a partir de la imagen o del proceso de generación de ésta. El ruido no nos permite tener una verdadera información radiométrica contenida en la imagen digital, desvalorizándola al encontrarse bajo estas condiciones (Lira, 2001). Por consiguiente, la remoción de ruido comúnmente precede a cualquier realce o clasificación subsecuente de los datos. El objetivo es restaurar la imagen al grado que se aproxime a la escena original (sin degradación) tanto como sea posible. La restauración está relacionada con el filtrado de la imagen observada para minimizar el efecto de degradación (Jain, 1989). En una restauración

<sup>1</sup> Un proceso estocástico es aquel que está regido por leyes probabilísticas.

se tiene un modelo del mecanismo de degradación a partir del cual se construye el ideal de imagen.

Las fuentes de ruido pueden ser el sensor o un fenómeno físico inherente al proceso de formación de la imagen. Los *pixeles* que podrían ser clasificados como ruido tienden a poseer valores de niveles de gris que visualmente aparecen fuera de lugar con respecto a los *pixeles* circundantes; esta observación es el fundamento de muchos algoritmos de limpieza de ruido (Pratt, 1991).

Por la manera en cómo afecta o modifica el ruido a una imagen, lo podemos clasificar de dos formas: aditivo o multiplicativo. Debido a que el ruido en la imagen es el resultado de un proceso físico de naturaleza estocástica es posible identificarlo con base en sus propiedades estadísticas; de acuerdo a su función de distribución, una imagen puede ser degradada por ruido multiplicativo o aditivo de tipo gaussiano (normal), exponencial, de Rayleigh, Poisson o de distribución uniforme entre las formas más comunes de modelación<sup>2</sup>.

### *Ruido Multiplicativo Speckle.*

Como se mencionó anteriormente, existe un tipo de ruido que es el resultado de un fenómeno físico inherente al proceso de formación de la imagen, tal es el caso del llamado *speckle* o moteado; visualmente aparece sobre impuesto en la imagen como una granulidad aleatoria formada por *pixeles* de varios brillos. Las imágenes deterioradas por ruido multiplicativo tienen la característica de que las áreas con mayor brillo son más ruidosas. El fenómeno es característico en imágenes generadas con radiación coherente tales como las de radar de apertura sintética (SAR), láser, ultrasonido, acústicas y de sonar.

Análisis teóricos (Ulaby et al., 1986) y experimentales (Lee, 1981) han mostrado que el *speckle* cumple con un modelo de ruido multiplicativo en el sentido de que su desviación estándar es proporcional a la media local y posee una función de distribución que depende de los métodos de detección y procesamiento de la señal empleados (Lee & Jurkevich, 1989). El modelo está dado por la ecuación (3.1-1)

$$f(x,y)=g(x,y) n(x,y) \quad (3.1-1)$$

donde  $g$  es la imagen verdadera,  $f$  la imagen observada y  $n$  es el ruido con media igual a 1 y desviación estándar de  $\sigma_n$ . La validez de este modelo puede verificarse graficando los valores de la desviación estándar en función de la media como lo muestra la Figura 3.2, obtenidas de varias áreas pequeñas uniformes donde deberá obtenerse aproximadamente una línea, ratificando con ello que la desviación es

<sup>2</sup> Para la mayoría de los sensores de imágenes, el ruido asociado a éstos puede ser modelado como un proceso aleatorio con distribución gaussiana o de Poisson; para mayor referencia consultar (Pratt, 1991)

proporcional a la media local,  $\sigma_f = A\mu_f$ , la pendiente de la recta (coeficiente de proporcionalidad) es precisamente el valor de la desviación estándar global del *speckle*.

Algunos algoritmos de realce (Jain, 1989), tal como la elongación o escalamiento lineal, no cambian la propiedad multiplicativa del ruido *speckle*. La elongación lineal, en particular, mantiene un valor constante de la desviación estándar del *speckle*. Otras operaciones de modificación del histograma, por ejemplo la ecualización, no tienen esta propiedad (Lee, 1986); por lo tanto un filtro debe ser aplicado a la imagen tal como fue generada por el sistema sensor (Pastrana, 1996).

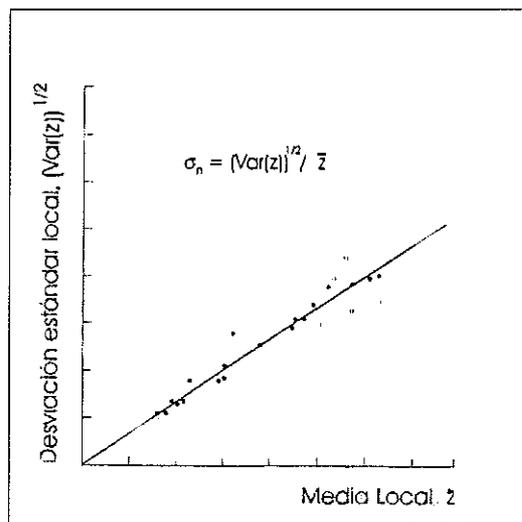


Fig. 3.2 Características del ruido *speckle* (Pastrana, 1996).

El *speckle*, que aparece en las imágenes SAR como un ruido granular y se muestra en la Figura 3.3, complica la interpretación, reduce la efectividad de la segmentación (Lee y Jurkevich, 1989; Lira y Landgrave, 1992; Chavira, 1996), la clasificación y otros procesos de extracción de información. Básicamente las técnicas de reducción de *speckle* en imágenes SAR cae dentro de una de dos grandes categorías: previa o posterior a la información de la imagen.

TESIS CON  
FALLA DE ORIGEN

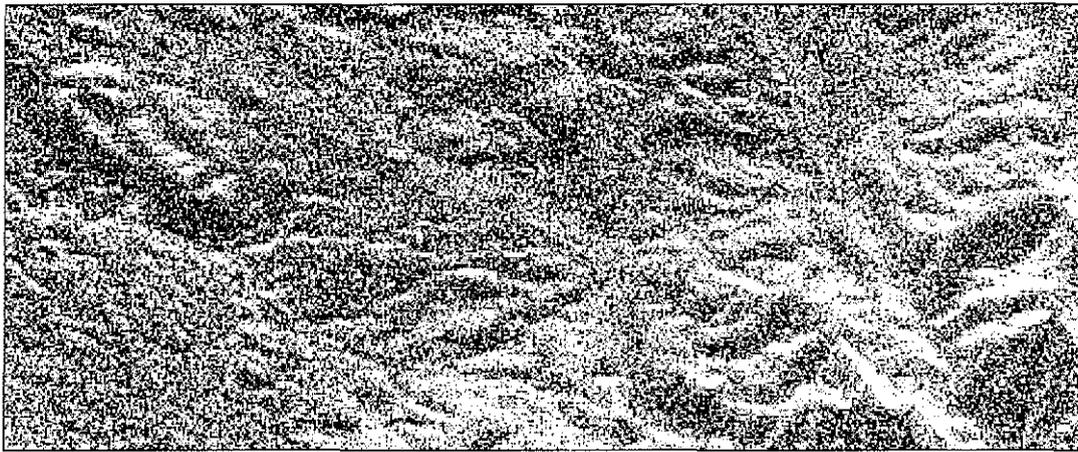


Fig. 3.3 Patrón típico de ruido multiplicativo speckle en imagen SAR.

### 3.1.1. Filtros.

La selección de uno o varios patrones espaciales en función de ciertas propiedades morfológicas<sup>3</sup> globales en una imagen digital, resulta en un proceso que se conoce como *Filtrado* (Lira, 1995). La elección discriminativa de estos patrones conduce a una segmentación de la imagen que facilita la medida en detalle de sus manifestaciones espaciales asociadas. En un filtro siempre se suprimen aquellos patrones que no son de interés o valor para el investigador, por lo que se puede decir que un filtro es un realce de tipo selectivo.

El filtraje de una imagen digital ha encontrado muchas aplicaciones en diferentes disciplinas de la investigación experimental, donde se emplean datos bidimensionales para extraer información acerca del comportamiento de un sistema físico. Se han estudiado hasta ahora muchos tipos de filtros que operan, ya sea en el dominio de la imagen o en el de frecuencias, los que son empleados en varias áreas del análisis de imágenes tales como: remoción de ruido, desarrollo de técnicas de suavizamiento, restauración de imágenes degradadas por un medio de interferencia, supresión de patrones selectos y en general, eliminación de cierto contenido de frecuencias en la imagen, todo esto con el propósito del realce selectivo de una o varias clases de patrones espaciales.

Por definición, el filtraje de una imagen es la única transformación donde en diversos niveles se pierde información; debido a la interdependencia de los valores de los procesos que generan cada pixel de la imagen digital, el filtraje ideal no puede ser alcanzado nunca y además de esto, la complejidad matemática con relación a la eficiencia computacional hace imperativo, en una variedad de casos, el buscar operaciones de filtraje más bien simples y de rápida ejecución. En lugar de buscar

<sup>3</sup> Se entiende por propiedades morfológicas a las características geométricas de un patrón, las cuales son: forma, perímetro, área y la textura que posee.

una situación ideal de filtraje, muchos autores (Huang, 1981; Cappellini et al, 1978; Izquierdo, 2001) han desarrollado simplificaciones y aproximaciones para filtrar una imagen tanto en el dominio de frecuencias como en el de la imagen misma; el objetivo de esto es la supresión eficiente de una clase de patrones.

### 3.1.1.1. Filtros en el dominio de la imagen.

Cuando se habla de simplificar el proceso de filtraje, se entiende la exploración de nuevos métodos que eviten la recurrencia a un espacio de frecuencias y que faciliten el diseño de funciones de filtraje correspondientes. Por otro lado, se han invertido muchos esfuerzos (Mastin, 1985) en la evaluación de las funciones de filtraje que trabajan en el dominio espacial. El filtraje espacial se realiza definiendo en primera instancia una operación sobre los *pixeles* contenidos en una subregión o ventana de la imagen, el resultado numérico de la operación substituye el valor de un pixel preestablecido de la ventana

$$p_s \xleftarrow{(k,l)} K(p_{ij}), (i, j; k, l) \in V_{mn} \quad (3.1.1.1-1)$$

donde  $V_{mn}$  es una subregión de la imagen, de dimensión  $m \times n$  *pixeles*,  $K$  es el kernel u operación aplicada a los *pixeles*  $p_{ij}$  de la ventana  $V_{mn}$  y  $(k,l)$  es la posición del pixel predeterminado cuyo valor va a ser substituido. La aplicación del kernel se repite cada vez que la ventana se desliza por toda la imagen, haciéndose un barrido como lo muestra la Figura 3.4.

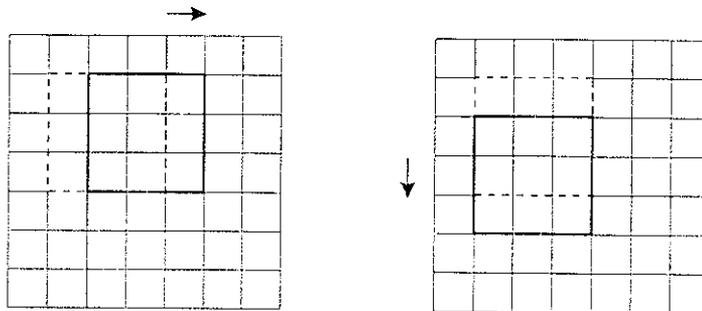


Fig. 3.4 Concepto de ventana y barrido de la misma sobre la imagen.

Existen varias propuestas para la reducción de ruido multiplicativo, las más importantes caen en la categoría de filtros en el dominio espacial, es decir, que trabajan directamente con los valores de la imagen y no aplican ningún tipo de transformación a los datos. Las técnicas de filtraje varían en complejidad, la mayoría

de ellas emplea una ventana de  $n \times n$  elementos, que se desliza por toda la imagen, para estimar el valor del pixel central.

Se presentarán a continuación algunos de los filtros espaciales existentes, con los cuáles se realizaron pruebas de filtraje y los resultados obtenidos fueron utilizados para evaluar la calidad y textura de las imágenes.

### Filtro de Lee.

El filtro semi-lineal concebido por Lee (1980) y después mejorado por él mismo (Lee, 1981), supone un ruido blanco aditivamente sobrepuesto a la imagen, con media  $\bar{v}$  igual a cero y una cierta varianza  $\sigma_v^2$ . Por tal motivo la imagen resultante  $x$  se escribe de la siguiente manera:

$$x(i,j) = s(i,j) + v(i,j), \forall(i,j) \quad (3.1.1.1-2)$$

donde  $s(i,j)$  es la imagen original y  $v(i,j)$  es el ruido aditivo. El diseño de este filtro es interesante ya que además de lo anterior, se supone que la media y la varianza de la imagen original pueden obtenerse a partir de la media y la varianza locales de la imagen degradada, es decir, que no se requiere de conocimiento a priori acerca del ruido, a diferencia de otros algoritmos donde se asume un modelo de autocorrelación para estimar la media y la varianza de la imagen original. La aproximación mencionada para este filtro se escribe como sigue:

$$\bar{x} = \bar{s} \quad (3.1.1.1-3)$$

y

$$\sigma_s^2 = E\{(s - \bar{s})^2\} = \sigma_x^2 - \sigma_v^2, \forall(i,j) \quad (3.1.1.1-4)$$

En otras palabras, la media de la imagen original coincide con la de la degradada y la varianza de la imagen original puede obtenerse a partir de la imagen degradada y de la estimación global de la varianza del ruido. Debido a que  $\sigma_x^2 = \sigma_s^2 + \sigma_v^2$ , la varianza de la imagen original se estima a partir de la degradada con el siguiente esquema

$$\sigma_s^2 = \begin{cases} \sigma_x^2 - \sigma_v^2, & \text{si } \sigma_x^2 > \sigma_v^2 \\ 0, & \text{de otra manera} \end{cases} \quad (3.1.1.1-5)$$

En la operación de este filtro se construye una ventana sobre la cual se evalúa cada vez la media y la varianza locales. Además de esto y antes de iniciar el algoritmo es necesario realizar una estimación de la varianza asociada al ruido global de la imagen; esto se hace generalmente en forma interactiva seleccionando una región

plana de la imagen donde se vislumbra claramente el ruido. Con estos datos se calcula lo que se conoce como factor de ganancia:

$$k(i, j) = \frac{\sigma_s^2(i, j)}{\sigma_s^2(i, j) + \sigma_v^2}, \forall(i, j) \quad (3.1.1.1-6)$$

que a su vez se aplica finalmente en el siguiente modelo de filtraje de la imagen degradada

$$s_{la}(i, j) = \bar{s}(i, j) + k(i, j)[x(i, j) - \bar{s}(i, j)], \forall(i, j) \quad (3.1.1.1-7)$$

De la familia de filtros no-lineales vale la pena mencionar, por su relativa sencillez operacional y por el buen comportamiento que presenta frente al filtraje de ruido gaussiano o blanco, el filtro de Lee multiplicativo (Mastin, 1985). Como su nombre lo indica, está diseñado para filtrar ruido multiplicativo, el cual puede ser tratado también como si fuese aditivo por medio de un filtro homomórfico. Cuando la estimación del ruido multiplicativo es buena, el comportamiento de estos filtros parece ser el mejor con respecto a otros tipos de filtros; existen propuestas basadas en estadísticas locales, el *filtro de Lee-Multiplicativo* (Lee, 1981) supera las dificultades del promedio indiscriminado que realiza un filtro de Media, la operación es ponderada mediante los parámetros de varianza y media de los *pixeles* en una ventana deslizante dando como efecto un mayor grado de filtraje en zonas homogéneas y ligero en las más rugosas (con bordes). Este filtro adaptivo concebido por Lee es un método ampliamente reconocido, varios investigadores han tomado dicho concepto para proyectar diferentes variantes de filtros para *speckle*.

#### Filtro de Kuan.

El filtro de Kuan (Kuan et al., 1985) ha sido concebido para filtrar ruido aditivo. La brillantez de la imagen observada  $I$  (la cual puede representar tanto la intensidad como la amplitud de la imagen) está dada como una función de una imagen ideal  $R(t)$  y ruido no correlacionado de media cero por medio de la siguiente ecuación:

$$I(t) = R(t) + V(t) \quad (3.1.1.1-8)$$

Se asume un modelo de una imagen con media y varianza no estacionaria, donde  $t=(x,y)$  es la coordenada espacial. La matriz de covarianza de la imagen puede entonces ser considerada diagonal. Por la expresión dada para  $I(t)$ , la señal original  $R(t)$  es estimada de modo que el error cuadrático medio sea mínimo. Además de que se ha impuesto que la estructura del estimador sea lineal. La estimación del filtro lineal MMSE<sup>4</sup> está entonces dada por:

<sup>4</sup> MMSE es el acrónimo de Minimum Mean Square Error.

$$\hat{R}(t) = \bar{I}(t) - [I(t) - \bar{I}(t)] \left[ \sigma_R^2(t) + \sigma_N^2(t) \right] \quad (3.1.1.1-9)$$

donde  $\bar{I}(t)$  es el valor promedio de la brillantez,  $\sigma_R^2(t)$  es la varianza de la señal original y  $\sigma_N^2(t)$  es la varianza del ruido.

En el caso donde la señal es independiente del ruido, los datos estadísticos locales de la imagen ideal pueden ser remplazados por una función de los datos estadísticos locales observados. Esto lleva al mismo filtro lineal como si se tratara del filtro de Lee para ruido aditivo.

El modelo de ruido multiplicativo para imágenes de radar es entonces considerado a partir del cual el filtro lineal es deducido. Puede ser escrito de la siguiente forma como una suma ponderada de los valores observados y la media:

$$\hat{R}(t) = I(t) W(t) + \bar{I}(t) (1 - W(t)) \quad (3.1.1.1-10)$$

donde la función de peso  $W$  está dada por:

$$W(t) = \left[ 1 - C_u^2 / C_I^2(t) \right] / \left[ 1 + C_u^2 \right] \quad (3.1.1.1-11)$$

y donde  $C_u$  es el coeficiente de la variación del ruido.

Kuan usa como base la técnica desarrollada por Lee con un algoritmo que calcula la varianza local de diferente forma (Kuan et al., 1985), donde lo que Kuan propone es usar la diferencia entre el pixel central y la media de una ventana de 3 x 3 *pixeles* como una medida aproximada de la varianza, el algoritmo en general pierde capacidad de reducción de speckle pero en zonas con bordes el ruido es menos *prominente* (Duran et al., 1987).

#### Filtro de Frost.

En el filtro de Frost (Lopes et al., 1990) se utiliza un modelo simplificado por la imagen adquirida como el que se da en la siguiente expresión:

$$I(t) = [R(t) \cdot u(t)] * h(t) \quad (3.1.1.1-12)$$

donde  $t=(x,y)$  es la coordenada espacial,  $R(t)$  es un proceso aleatorio estacionario que describe la reflectividad de la superficie de cada punto contenido en un área homogénea,  $u(t)$  es el ruido multiplicativo modelado por un proceso aleatorio no-gaussiano, blanco, real y estacionario con una función de densidad de probabilidad  $x^2$  y  $h(t)$  es la respuesta al impulso de un sistema. Para la estimación de la reflectividad  $R(t)$  en una imagen ideal es aplicado un filtro de error cuadrático medio

(MMSE), asumiendo datos de una imagen estacionaria, aunque este calculo puede ser no necesario ya que es suficiente con el valor del pixel que se tenga. Por lo que tendríamos la siguiente expresión:

$$I(t) = R(t) \cdot u(t) \quad (3.1.1.1-13)$$

Frost (Frost et al., 1982) propone un filtro espacial adaptivo usando una ventana de 5 x 5, a diferencia de Lee el promedio ponderado depende de una función exponencial cuya constante de decaimiento está en función de las características estadísticas locales dadas por la media y varianza de la ventana. Las características de este filtro son similares a aquellas del filtro estadístico local salvo en las zonas con bordes donde Frost realiza una mayor reducción de ruido, sin embargo experimentalmente se ha encontrado que los bordes aparecen algo borrosos (suavizados) y computacionalmente es de mayor demanda (Pastrana, 1996).

### Filtro Geométrico.

Métodos alternativos basados en operaciones morfológicas se han venido desarrollando para mejorar la calidad de las imágenes afectadas por *speckle*. El filtro geométrico es uno de ellos, reduce ruido multiplicativo *speckle* sobre una línea de la imagen a la vez usando un algoritmo denominado “*convex-hull*” (Serra, 1982) cuyo origen se remonta al realce de imágenes médicas y está basado en la aplicación de la transformación morfológica “*intersecta o no intersecta*” (Pratt, 1991).

Este filtro funciona bien para imágenes que contienen ruido multiplicativo tales como imágenes de radar, tomografías computadas y radiografías con rayos-x de alta energía (Crimmins, 1985), si bien opera por ventanas tiene una naturaleza diferente a los anteriormente discutidos. En este filtro la ventana no se desliza sobre la imagen sino sobre los perfiles de renglones, columnas y diagonales de la misma; en cada posición de la ventana se aplica una operación morfológica de “*intersecta o no intersecta*” empleando factores de peso adecuados para la reducción del ruido multiplicativo presente en la imagen. El procedimiento en detalle de este filtro es el siguiente: Un perfil dado de una imagen contaminada por ruido, como la que se mostró en la Figura 3.3, se binariza haciendo unos debajo de la curva y ceros por encima de ésta; al conjunto de unos se le llama la umbra del perfil, los ceros forman el complemento de ésta. Se consideran ahora las siguientes cuatro máscaras

1					
1	0				
1	1				

1	0				
1	1	1			

		0	1		
1	1	1			

			1		
		0	1		
	1	1			

Fig. 3.5. Máscaras empleadas: umbra.

de tal manera que cada una de ellas es deslizada sobre todos los *pixeles* de la frontera superior de la umbra, en cada posición se realiza una operación de “*intersecta o no-intersecta*”, por lo que si el patrón de unos de las máscaras coincide con el del perfil de la umbra, el pixel en correspondencia con el central de éstas es cambiado de cero a uno. En las posiciones donde no están definidos los factores de peso de las máscaras simplemente no se hace comparación con los de la umbra. De acuerdo con la operación morfológica arriba descrita, las cuatro máscaras se aplican entonces secuencialmente a los perfiles de los renglones, columnas diagonales y contradiagonales (de acuerdo al código de Freeman) que forman la imagen. El procedimiento computacional consiste en aplicar una máscara tras otra a los perfiles mencionados, no importando el orden de aplicación. Al terminar esta parte del algoritmo se consideran ahora las siguientes cuatro máscaras:

1	1	
1	0	
1		

1	1	1
1	0	

1	1	1
	0	1

	1	1
	0	1
		1

Fig. 3.6. Máscaras empleadas: complemento de la umbra.

las cuales se aplican ahora en el mismo esquema del procedimiento morfológico anterior, pero operando sobre el complemento de la umbra de los perfiles generados en la primera parte del algoritmo. Estas dos partes forman lo que se conoce como una iteración del algoritmo. El filtro morfológico muestra un buen comportamiento en la reducción del ruido multiplicativo, preservando correctamente los bordes, líneas y detalles texturales (Pastrana, 1996).

### Filtro Sigma Local.

El filtro sigma (Lee, 1983) está basado en la probabilidad sigma de una distribución gaussiana. El ruido de la imagen es filtrado promediando sólo aquellos *pixeles* dentro del rango de dos desviaciones estándar del pixel central, en consecuencia las características de alto contraste son preservadas, sin embargo, las motas oscuras de ruido no son removidas.

Una variante de este método de filtrado (Martín y Turner, 1993) realiza un promedio ponderado de los *pixeles* que caen dentro del rango de dos desviaciones estándar con base en una función de probabilidades gaussianas.

Se puede decir que este tipo de filtro se aplica sobre todo para ruido aditivo. Se sabe que dada una función de densidad de probabilidad gaussiana con media  $\mu$  y varianza  $\sigma^2$ , el 95.5% de la población se encuentran dentro de cierto rango ( $\mu - 2\sigma, \mu + 2\sigma$ ). Asumiendo el valor del pixel como

$$z(i,j)=x(i,j)+n(i,j) \quad (3.1.1.1-14)$$

con  $E[n(i,j)]=0$  y  $E[n^2(i,j)]=\sigma^2$ , es entonces una estimación uniforme de la media no estacionaria  $\mu=\mu(i,j)$  de la señal  $x(i,j)$ , un promedio local es calculado solamente sobre una muestra presumiblemente homogénea dentro de la ventana local de barrido, esto es sobre aquellos *pixeles* cuyo nivel de gris cae dentro del rango  $z(i,j)-2\sigma \div z(i,j)+2\sigma$ . El contorno geométrico y la cardinalidad del grupo local, cuyos *pixeles* están promediados para producir la salida, dependen de los valores de los *pixeles* vecinos con respecto al pixel central, de esta manera realizando un promedio condicional.

Una versión del filtro sigma ha sido introducida y trabajada (Lee, 1983 y 1986). Denotando con  $z(i,j)=x(i,j) + v(i,j)$  el valor del pixel observado, donde  $x(i,j)$  es el valor del pixel libre de ruido y  $v(i,j)$  el ruido speckle pseudo-blanco, independiente de  $x$ , con una media unitaria y desviación estándar  $\sigma_v$ .

Si localmente  $E[x^2]=E[x]^2=\bar{x}^2$ , la varianza de  $z$  sería  $\sigma_z^2=\bar{x}^2 \sigma_v^2=\bar{z}^2 \sigma_v^2$ , por lo tanto  $\sigma_z$  es igual al producto de  $\sigma_v$  por el promedio local de  $z$ , lo cual ocasiona que la variabilidad dependa solamente del speckle, esto es cierto si  $x(i,j)$  es localmente uniforme.

### 3.1.2. Criterios de evaluación de la calidad de una imagen.

El desempeño de un método de reducción de ruido se mide principalmente con base en la calidad de la imagen resultante, para determinar la calidad de una imagen se requiere establecer un conjunto de criterios de evaluación cuantitativos y cualitativos que en su conjunto nos permitan saber en qué aspectos falla o acierta un algoritmo de filtrado.

Una imagen digital es una representación de una escena bajo estudio, como tal su estructura y aspecto visual son importantes en cuanto a las conclusiones que pudieran derivarse acerca del comportamiento de la escena. Por otro lado, la fidelidad con la que la imagen digital caracteriza la escena es un aspecto que constituye una premisa básica en el análisis cuantitativo de patrones. De acuerdo con esto, es necesario plantear con cierto detalle el concepto de *calidad de una imagen* que permita cuantificar el resultado de una transformación realizada a ésta o su contenido de información con relación a la escena que representa.

La calidad de una imagen está relacionada, en primera instancia, con el número de *pixeles* y escala de cuantización (niveles) con los que haya sido discretizada la escena correspondiente (*resolución*). Otros factores de los cuales depende la calidad de la imagen son el *contraste global*, la *definición de bordes* y el *contenido de ruido*. Si se desea una óptima calidad, es necesario que el contraste sea

el máximo posible, la definición de los bordes sea precisa y el contenido de ruido sea mínimo.

La calidad de la imagen depende, de una manera compleja (Rosenfeld y Kak, 1982), de todos los parámetros arriba discutidos y es una medida que debe determinarse tanto para la imagen original como para cualquier transformación de ésta.

### 3.1.2.1. Descriptores Globales.

Para determinar la calidad de una imagen se puede hacer en función de ciertos descriptores globales, los cuales toman en cuenta todos los *pixeles* contenidos en la imagen para obtener y calcular dichos descriptores o factores.

#### Resolución.

El tamaño del campo instantáneo de vista (CIV) define la *resolución espacial*, es decir, da el grado de detalle que se puede discernir de la escena; a su vez, los niveles de grises definen el número de tonos discernibles y con ello la resolución radiométrica, en otras palabras, proporciona una medida de qué tanto se puede distinguir una energía luminosa de otra (Lira, 1987).

#### Factor Contraste.

Está relacionado con la apariencia visual de la imagen, es en general una función de las coordenadas (x,y), ya que las condiciones de iluminación respectiva pueden cambiar. El contraste es una propiedad local de la imagen, por lo que se define como la relación de valor que tiene uno o varios *pixeles* con los vecinos próximos. Al definir *factores de contraste* en una imagen digital evitamos la subjetividad de la apreciación visual, ya que estos factores resultan en una cantidad numérica que depende de los valores de los *pixeles* en una vecindad predefinida. Algunos modelos que se utilizaron en este trabajo de tesis son el de promedio central, máximo-mínimo y logarítmico.

Sea  $p_c$  el valor del pixel central de una ventana de 3 x 3 *pixeles* y sea  $\bar{p}$  el promedio de sus elementos vecinos en conectividad-8, entonces un factor de contraste, al que llamaremos promedio-central, es el siguiente:

$$\text{promedio central} \quad fc_1 = \frac{|p_c - \bar{p}|}{p_c + \bar{p}}, \quad \forall (p_c + \bar{p}) > 0. \quad (3.1.2.1-1)$$

Esta es una medida puntual, pero es posible generalizarla a una región si  $p_c$  es el promedio de los *pixeles* de una ventana de  $3 \times 3$  y  $\bar{p}$  es el promedio de las ventanas de  $3 \times 3$  que la rodean. Con la misma forma de la relación (3.1.2.1-1) es posible evaluar el contraste de un objeto con su entorno, en este caso  $p_c$  sería el promedio de los valores de los *pixeles* que componen el objeto y  $\bar{p}$  sería el promedio de los *pixeles* circundantes.

Otro modelo del contraste es que en una ventana cuadrada se encuentran los valores máximo y mínimo con los que se establece el siguiente cociente:

$$\text{máximo-mínimo} \quad fc_2 = \frac{p_{\max} - p_{\min}}{p_{\max} + p_{\min}}, \quad \forall (p_{\max} + p_{\min}) > 0. \quad (3.1.2.1-2)$$

Es conocido (Pratt, 1991) que la respuesta natural del ojo a las variaciones de intensidad es no-lineal, y específicamente es logarítmica; con base en este hecho surge un tercer modelo:

$$\text{logarítmico} \quad fc_3 = a \log(u + 1), \quad 0 \leq u \leq b. \quad (3.1.2.1-3)$$

donde  $u = |p_c - \bar{p}|$ ,  $a = \text{cte}$ ,  $b = 2^n - 1$ , con  $n$  igual al número de bits/píxel.

El factor de contraste de la expresión (3.1.2.1-3) está determinado por el logaritmo de la diferencia absoluta entre el píxel central ( $p_c$ ) y el promedio de sus próximos vecinos ( $\bar{p}$ ).

Con cualquiera de los tres criterios es posible realizar el barrido de la ventana sobre todos los *pixeles* de la imagen para obtener su *distribución de contraste*. Si promediamos los factores de contraste de cada píxel cuantificamos el *contraste global* de la imagen o de una región:

$$fc_{\text{global}} = \frac{\sum_{j=2}^{m-1} \sum_{i=2}^{n-1} fc(i, j)}{(m-2)(n-2)} \quad (3.1.2.1-4)$$

donde  $fc(i, j)$  es el factor de contraste del píxel en la posición  $(i, j)$ -ésima empleando una ventana de  $3 \times 3$ ,  $m$  y  $n$  son las dimensiones de la imagen.

### Media Global.

Es la media de la imagen en general, se calcula tomando en cuenta todos los *pixeles* contenidos en la imagen y obteniéndose un valor promedio de éstos, se define como  $\mu_{\text{global}}$  mediante la siguiente expresión:

$$\mu_{\text{global}} = \frac{1}{(m \times n)} \sum_{j=1}^M \sum_{i=1}^N p(i, j) \quad (3.1.2.1-5)$$

donde  $p(i, j)$  es el valor de cada pixel en la posición  $(i, j)$ -ésima, así como  $m$  y  $n$  son las dimensiones de la imagen.

### Desviación Estándar Global.

En el caso de la desviación estándar global también se toman en cuenta todos los *pixeles* que se encuentran contenidos en la imagen, se define como  $\sigma$  mediante la siguiente expresión:

$$\sigma_{\text{global}} = \left[ \frac{1}{(m \times n)} \sum_{j=1}^m \sum_{i=1}^n \{p(i, j) - \bar{p}\}^2 \right]^{1/2} \quad (3.1.2.1-6)$$

donde  $\bar{p}$  es el valor promedio ( $\mu_{\text{global}}$ ) de la imagen.

### Dispersión.

La dispersión está dada por la raíz cuadrada del cociente de la media global entre la desviación estándar global, es decir, se encuentra dada por la siguiente expresión:

$$\text{dispersión} = \sqrt{\frac{\mu_{\text{global}}}{\sigma_{\text{global}}}} \quad (3.1.2.1-7)$$

#### 3.1.2.2. Descriptores Locales.

Los descriptores o factores locales se refiere a la aplicación de los criterios cuantitativos a una región específica de interés dentro de la imagen, algunos de los factores locales son la media local, la desviación estándar local, el contenido de ruido (índice *speckle*), la relación de la señal-ruido, así como ciertos porcentajes de homogeneidad. A continuación se especifica cada uno de estos criterios.

### Media Local.

Es la media o valor promedio de los *pixeles* contenidos en una zona de la imagen, se calcula tomando en cuenta los *pixeles* contenidos en cierta vecindad, es decir, es el valor promedio  $\mu$  de  $f(x,y)$  en la vecindad. Si se considera una vecindad de tamaño dado por  $(2p+1)$  por  $(2q+1)$  alrededor de un punto  $(x, y)$ ,  $\mu$  quedaría expresada como:

$$\mu_{local} = \frac{1}{(2p+1)(2q+1)} \sum_{m=-p}^p \sum_{n=-q}^q f(x+m, y+n) \quad (3.1.2.2-1)$$

Podemos decir que la media  $\mu$  representa una aproximación al valor verdadero o información de la imagen sin ruido debido a que las contribuciones del ruido son tanto negativas (valles) como positivas (picos) con respecto a la media.

### Desviación Estándar Local.

La desviación estándar local de  $f(x, y)$  en la posición  $(x, y)$ , para una zona de la imagen, tomando la misma consideración de vecindad como en la media local, estaría dada por la siguiente expresión:

$$\sigma_{local} = \left[ \frac{1}{(2p+1)(2q+1)} \sum_{m=-p}^p \sum_{n=-q}^q \{f(x+m, y+n) - \bar{f}(x, y)\}^2 \right]^{1/2} \quad (3.1.2.2-2)$$

donde  $\mu_{local} = \bar{f}(x, y)$  es la media local.

La desviación estándar es una medida de la dispersión de los datos. Es conveniente resaltar la importancia que tiene  $\sigma$  en zonas homogéneas, ya que su valor está determinado principalmente por la presencia del ruido.

### Contenido de Ruido.

Estimar la cantidad de ruido (Olsen, 1993) presente en una imagen es necesario para cuantificar el grado de reducción que ejerce un filtro al aplicarlo a la imagen una o varias iteraciones, así como procesarla óptimamente con algún algoritmo ya sea de detección de bordes, segmentación o restauración. El nivel de ruido se mide con el cociente de la desviación estándar y la media calculados en una región homogénea de la imagen degradada por ruido, quedando definido por la siguiente expresión:

$$\beta = \frac{\sigma_{local}}{\mu_{local}} \quad (3.1.2.2-3)$$

donde  $\sigma_{local}$  y  $\mu_{local}$  están definidos como se indicó anteriormente.

Para el caso de ruido multiplicativo se ha llegado a denominar a esta relación como índice *speckle*.

### Relación Señal – Ruido.

De acuerdo a lo anterior se puede aproximar el cociente de la media y la desviación estándar como una relación señal a ruido (Durand et al., 1987). Por lo que quedaría definida como  $snr^5$  y se expresaría de la siguiente manera:

$$snr = \frac{\mu_{local}}{\sigma_{local}} \quad (3.1.2.2-4)$$

Cabe señalar que el cociente de la desviación y la media, así como su inverso, sólo tienen un significado cuando son calculados en una región homogénea.

### Homogeneidad.

Un aspecto que está relacionado con el proceso de reducción de ruido es la modificación de las texturas en la imagen. Una textura aparentemente suave, sin bordes grandes, puede no serlo si existe ruido sobreimpuesto ya que contribuye con frecuencias espaciales altas. Por otro lado, si el ruido está presente en una región rugosa con bordes notables, grandes, anchos y estrechos, la textura estará definida principalmente por las rugosidades más que por el ruido.

Un filtro incrementa la homogeneidad de una textura suave al remover el ruido, mientras que en una textura rugosa el grado de heterogeneidad disminuye poco. Para cuantificar el grado de homogeneidad que posee una zona, definimos dos factores basados en datos estadísticos:

$$\varepsilon_1 = \frac{1}{1 + \sigma_{local}} \quad y \quad \varepsilon_2 = \frac{1}{1 + \frac{\sigma_{local}}{\mu_{local}}} \quad (3.1.2.2-5)$$

en el caso de  $\varepsilon_1$ , cuando se está examinando una zona plana,  $\sigma=0$  y  $\varepsilon_1 = 1$ ; en una región muy heterogénea (textura rugosa)  $\sigma \gg 1$  y  $\varepsilon_1 \cong 0$ ; el segundo factor de homogeneidad tiene un comportamiento semejante al primero con la diferencia de que produce datos más grandes debido a que la desviación estándar está dividida entre la media, esto con el objeto de reducir la contribución del ruido a la desviación total (a mayor media, mayor nivel de ruido).

<sup>5</sup> *snr* es el acrónimo de Signal-Noise Relation.

### 3.1.2.3. Histograma.

Una herramienta objetiva que nos permite evaluar la calidad de tonos o radiométrica de una imagen es su histograma, como el que se muestra en la Figura 3.7.

Éste representa la frecuencia relativa de ocurrencia de los diferentes niveles de gris en la imagen (Jain, 1989), por lo que también se le conoce como la función de distribución de probabilidad discreta (Pelag, 1978; Richards, 1986), definida por la siguiente relación:

$$p_r(r_k) = \frac{n_k}{n} \quad 0 \leq r_k \leq 1 \quad k = 0, 1, \dots, L-1 \quad (3.1.2.3-1)$$

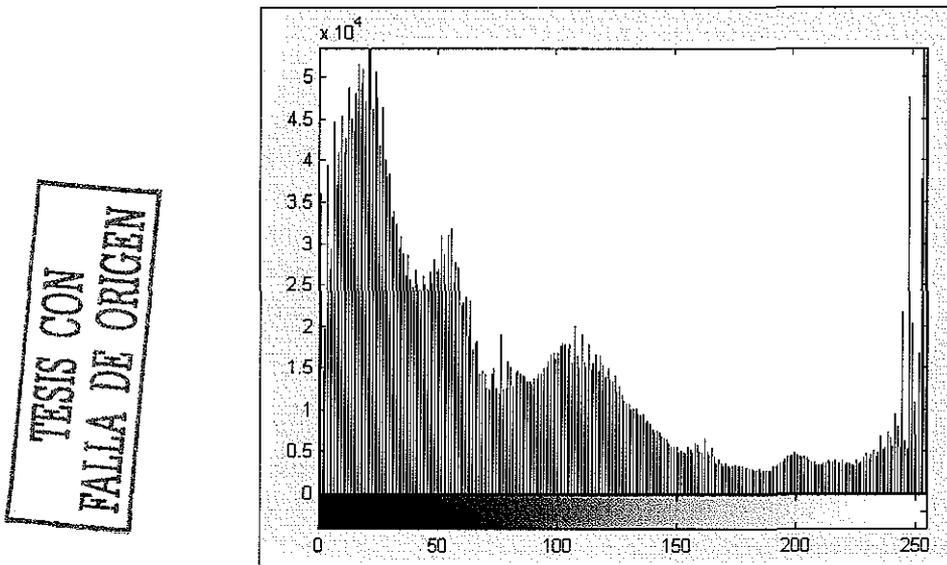


Fig. 3.7 Histograma.

donde  $L$  es el número de niveles,  $p_r(r_k)$  es la probabilidad del  $k$ -ésimo nivel de gris,  $n_k$  es el número de veces que este nivel aparece en la imagen y  $n$  es el número total de *pixeles* en la imagen. Una gráfica de  $p_r(r_k)$  contra  $r_k$  es generalmente llamada histograma.

Un histograma proporciona una descripción global de la apariencia de una imagen, a partir de este se deduce si la imagen tiene poco contraste (histograma estrecho), buen contraste<sup>6</sup>, o si la imagen tiene o no predominancia de cierto conjunto de tonos.

<sup>6</sup> Una imagen que hace un buen uso del rango de tonos de gris disponibles tiene un histograma con barras ocupando todo el rango, pero sin barras largas significativas en el nivel negro (0) y blanco (255).

### 3.1.2.4. Detección de Bordes.

Ciertos cambios o discontinuidades de la amplitud o valor de los *pixeles* en una imagen son características primitivas fundamentalmente importantes, porque a menudo proporcionan un indicador de la extensión física de los objetos dentro de la escena. Las discontinuidades locales en una imagen de un nivel a otro de pixel son llamadas *bordes* (Pratt, 1991).

### MODELOS DE BORDES.

La Figura 3.8 contiene un esquema con perfiles de los modelos de bordes ideales. Una *rampa* es un incremento de amplitud de un nivel bajo a uno alto de pixel o viceversa. El borde está caracterizado por su altura, ángulo de inclinación (pendiente) y la coordenada horizontal del punto medio de la pendiente. Si el ángulo de inclinación es de  $90^\circ$ , el borde resultante es llamado *escalón*. En el límite cuando el ancho de la línea  $w$  se aproxima a cero, la discontinuidad de la amplitud resultante es llamada borde tipo triangular.

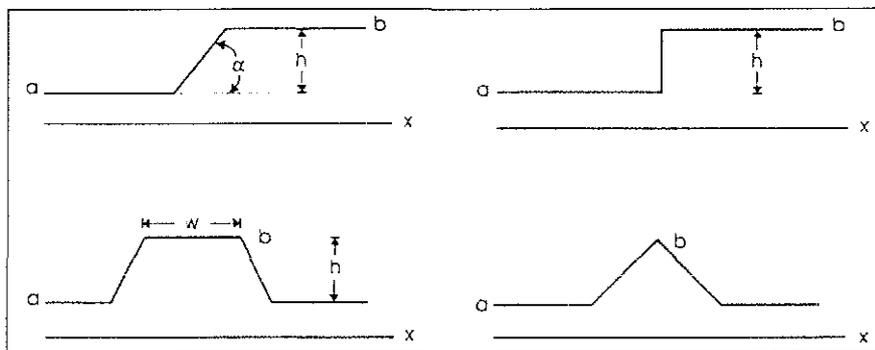


Fig 3.8. Modelos de bordes: borde tipo rampa, tipo escalón, tipo línea, tipo triangular.

La Figura 3.9 contiene modelos de bordes tipo escalón, rampa, triangular y *mota* en el dominio discreto de la imagen. Una *mota* (spot) o mancha, la cual sólo puede ser definida en dos dimensiones, consiste de una meseta de amplitud grande frente a un fondo de menor amplitud o viceversa.

00004444	000134444	000242000	000000000
00004444	000134444	000242000	000000000
00004444	000134444	000242000	000222000
00004444	000134444	000242000	000242000
00004444	000134444	000242000	000222000
00004444	000134444	000242000	000000000
00004444	000134444	000242000	000000000
Escalón	Rampa a= 0	Triangular b=4	Spot o Mota

Fig. 3.9. Bordes bidimensionales.

Un problema de fundamental importancia en el análisis de imágenes es la *detección de bordes* (Jain, 1989). Los bordes caracterizan los límites o frontera de los objetos y por lo tanto es útil para la segmentación, registro e identificación de objetos en una escena.

La idea fundamental de la mayoría de las técnicas de detección de bordes es la aplicación de operadores de diferencias locales (Gonzalez y Wintz, 1987). Kirsch (Kirsch, 1971; Pratt, 1991) ha propuesto un operador de diferencias multidireccional para la detección de bordes, el cual está definido por:

$$G(j,k) = \text{MAX}_{i=0}^7 [|5S_i - 3T_i|] \quad (3.1.2.4-2)$$

donde

$$S_i = A_i + A_{i+1} + A_{i+2}$$

$$T_i = A_{i+3} + A_{i+4} + A_{i+5} + A_{i+6} + A_{i+7}$$

$$\text{MAX}_{i=0}^7 = \text{máximo de las diferencias en las ocho direcciones}$$

El subíndice  $i$  es evaluado en módulo 8. Los elementos  $A_i$ -ésimos se ubican en la ventana de 3 x 3 conforme a la siguiente convención:

$A_0$	$A_1$	$A_2$
$A_7$		$A_3$
$A_6$	$A_5$	$A_4$

Este detector identifica como borde a la variación de tono de gris o valor de pixel más significativa que ocurra en alguna de las ocho direcciones posibles con respecto a la posición  $(j, k)$  de la imagen.

### 3.1.3. Comparación de Descriptores.

Una vez definido el modelo de reducción de ruido es necesario evaluar su efectividad. A continuación se realizan y analizan pruebas efectuadas a una imagen prueba para comparar el comportamiento y resultados obtenidos entre algunos filtros comunes como el filtro Geométrico, el filtro de Lee-Multiplicativo, el filtro de Frost, el filtro de Kuan y el filtro de Sigma, la discusión se realiza con base en los resultados obtenidos de las pruebas efectuadas con el objeto de encontrar con cuál de estos filtros se obtienen un filtrado óptimo en la imagen de prueba, para posteriormente utilizar la imagen ya filtrada en el proceso para determinar texturas, lo cual se explica más adelante en este capítulo.

#### 3.1.3.1. Pruebas realizadas.

En este trabajo de tesis se utilizó una imagen de radar Seasat y la imagen Landsat de una zona del Norte de México, la cual abarca parte de los estados de Coahuila, Chihuahua y Nuevo León. En el Anexo A se muestra el proceso de registro y corrección geométrica de la imagen Seasat con respecto a la imagen Landsat y a las coordenadas geográficas correspondientes, que se requirió hacer antes de realizar las diferentes pruebas.

Se procedió con el filtrado de la imagen Seasat original degradada por ruido y posteriormente se llevo a cabo la aplicación de los criterios de evaluación tanto cuantitativos como cualitativos a la imagen Seasat filtrada. En una imagen típica degradada por speckle fueron verificadas las características estadísticas del ruido.

#### Filtrado de Imágenes.

Se seleccionó una imagen (ver Anexo B) que abarcara el área de estudio y que estuviera degradada por ruido speckle para evaluar las bondades del filtro 'Geométrico' y poderlo comparar con los métodos de Lee-Multiplicativo, Frost, Kuan y Sigma (Pastrana, 1996). Una subregión de una imagen tipo SAR fue seleccionada para dicho propósito, dada su riqueza en texturas; esta imagen cubre la porción Este del anticlinal de Obayos, aproximadamente 100 Km al norte de la ciudad de Monclova, Coahuila. Posee una dimensión de 998 x 998 *pixeles*, con una resolución de 25 x 25 m<sup>2</sup> por pixel; este es el resultado de un proceso generado por el sistema de radar abordo del satélite SEASAT y tratada posteriormente a 4-looks; la fecha de adquisición fue en el año de 1978.

La imagen original degradada por ruido fue filtrada con una y dos iteraciones del filtro geométrico, los otros cuatro algoritmos fueron aplicados una sola vez empleando una ventana de 3 x 3 *pixeles*, y en su caso respectivo se especificó una desviación estándar del ruido  $\sigma_v=0.27$ , dato estimado de la imagen misma (Pastrana, 1996).

Los factores y criterios de evaluación para la calidad de una imagen se implementaron programando los algoritmos respectivos utilizando Matlab.

Un primer criterio que se implementó es el de contraste de acuerdo a lo siguiente:

$$\begin{aligned} \text{si } p_c + \bar{p} > 0 &\Rightarrow fc_1 = a \left[ \frac{|p_c - \bar{p}|}{(p_c + \bar{p})} \right] \\ \text{o si } p_c + \bar{p} = 0 &\Rightarrow fc_1 = 0 \end{aligned}$$

donde  $a=255$  para normalizar los datos en un rango de 0 a 255,  $p_c$  es el pixel en la posición  $(x,y)$  y  $\bar{p}$  es el promedio de los 8 *pixeles* vecinos dentro de una ventana de 3 x 3 *pixeles*, centrada en  $(x,y)$ . La ventana se desliza por toda la imagen, el contraste global es calculado promediando los factores de cada posición de la imagen, donde tanto los valores del contraste global como los parciales son redondeados.

Posteriormente es aplicado el segundo factor de contraste:

$$\begin{aligned} \text{si } p_{\max} + p_{\min} > 0 &\Rightarrow fc_2 = 255(p_{\max} - p_{\min}) / (p_{\max} + p_{\min}) \\ \text{o si } p_{\max} + p_{\min} = 0 &\Rightarrow fc_2 = 0 \end{aligned}$$

donde  $p_{\max}$  y  $p_{\min}$  son los valores más grandes y el menor de los nueve datos de la ventana centrada en  $(x,y)$ .

El factor de contraste algorítmico se implantó de la siguiente forma:

$$fc_3 = 106 \log |p_c - \bar{p}| + 1$$

donde la diferencia  $p_c - \bar{p}$  es reescalada sumándole la unidad con el objeto de no tener logaritmos negativos, ya que esto no tiene una interpretación lógica bajo el concepto de contraste. La constante igual a 106 es utilizada para manejar valores en un rango de 0 a 255. Al igual que en los dos primeros casos, los resultados parciales así como el valor global son redondeados.

El programa también calcula los datos estadísticos de toda la imagen. La media es obtenida leyendo uno por uno el valor de los *pixeles*, sumándolos y el resultado es dividido por el número total de *pixeles* en la imagen. En la desviación estándar se va acumulando el cuadrado de la diferencia del valor de cada pixel y media global, después la suma de los valores obtenidos es dividida entre el número total de *pixeles* de la imagen, y finalmente la dispersión es calculada como la raíz cuadrada de la desviación estándar.

Para la opción de los criterios locales, los factores de contraste, la media y la desviación estándar son datos obtenidos directamente de la zona que se halla elegido;

con base en los dos últimos se calcula el índice de speckle, relación señal a ruido y los porcentajes de homogeneidad. El índice de speckle está definido dentro del programa como:

$$\begin{aligned} &\text{si } \mu > 0 \Rightarrow \beta = \sigma / \mu \\ &\text{o si } \mu = 0 \Rightarrow \beta = 0 \end{aligned}$$

La relación señal a ruido:

$$\begin{aligned} &\text{si } \sigma > 0 \Rightarrow \text{snr} = \mu / \sigma \\ &\text{o si } \sigma = 0 \Rightarrow \text{snr} = \infty \end{aligned}$$

donde  $\infty$  en el programa significa enviar de snr el mensaje ‘infinito’.

Los porcentajes de homogeneidad están dados por las siguientes relaciones:

$$\varepsilon_1 = 100(1 + \sigma) \quad \text{y} \quad \varepsilon_2 = 100 / (1 + (\sigma / \mu))$$

Obviamente la constante en el numerador es para producir datos en términos porcentuales.

### Aplicación de Criterios Cuantitativos.

Tres factores, promedio-central ( $fc_1$ ), máximo-mínimo ( $fc_2$ ) y logarítmico ( $fc_3$ ) determinan en una escala de 0 a 255 el grado de contraste que posee la imagen que se desea examinar. Datos estadísticos como la media ( $\mu$ ) y desviación estándar ( $\sigma$ ) se combinan para medir el índice speckle ( $\beta$ ), la relación señal ruido (snr) y el porcentaje de homogeneidad ( $\varepsilon$ ) en una región específica.

Los criterios de evaluación se aplican en forma global y local, algunos datos generados tienen una interpretación distinta dependiendo de la zona en que sean obtenidos.

Para el caso de una evaluación global se encuentran los factores de contraste (promedio central, máximo-mínimo y logarítmico), así como la media, la desviación estándar y la dispersión; donde los resultados que se esperan obtener son un valor de los factores de contraste alto, que se conserve el valor de la media original y se reduzca el valor de la desviación estándar.

Ahora bien, para una evaluación local se encuentran, como en el caso de la evaluación global, la media y la desviación estándar, además del nivel de ruido, los dos factores de homogeneidad y se calcula la relación señal-ruido.

Se espera que los resultados de estos criterios de evaluación, para el caso de una región homogénea, sean un factor de contraste bajo y se conserve el valor de la media, mientras que el valor de la desviación estándar y del índice de speckle tengan un valor mínimo, no así el valor de la relación señal-ruido, junto con los factores de homogeneidad ya que se quiere que estos valores sean máximos. Si se trata de una región con textura rugosa, en la que se requiera cuantificar el deterioro o suavizado que produce la aplicación de un filtro sobre dicha textura, donde el valor de la desviación estándar está principalmente determinado por los bordes más que por la presencia del ruido, se buscará que los valores de contraste sean más altos, así como la menor variación de la media, un gran efecto de reducción de ruido, un incremento considerable de la relación señal-ruido, menor variación de la desviación estándar en zona rugosa, un crecimiento del porcentaje de homogeneidad y la conservación de la heterogeneidad en zona rugosa.

Bajo las condiciones anteriores se espera que la imagen filtrada con mayor calidad tenga factores de contraste altos, conserve la media, mientras que la disminución de la desviación estándar sea la menor así como el incremento en el grado de homogeneidad sea mínimo y que sus valores sean pequeños.

### Calidad Visual.

La evaluación de la calidad perceptible (Escalante et al., 1995) de imágenes naturales es a menudo estudiada como una simple impresión psicológica determinada directamente por varios parámetros físicos. Sin embargo y especialmente cuando las imágenes contienen diferentes tipos de degradación, es más apropiado considerar que la calidad global de la imagen está determinada por distintos atributos perceptuales tales como la *agudeza de bordes*, *ruido percibido* y *contraste*. En una representación visual de una imagen digital la definición de bordes se plasma como un efecto de enfoque, cuando aquellos están suavizados o truncados la imagen se ve desenfocada y cuando los bordes son agudos la imagen se define nítida. El contraste se refleja en la capacidad para poder distinguir unos objetos de otros, si una imagen tiene poco contraste los objetos cuya respuesta radiométrica difiera poco no podrán ser distinguidos visualmente. A pesar de que el ser humano es capaz de extraer información embebida en ruido, llenar líneas aparentemente faltantes o incompletas y de precisar la presencia de un objeto aún si se encuentra parcialmente sombreado, dependiendo de la cantidad presente en la imagen, el ruido puede llegar a ensombrecer o deteriorar la información (texturas, objetos y pequeños detalles) al grado de no poderla distinguir visualmente, el ruido se manifiesta en la imagen como *pixeles* cuyos valores de gris son notablemente diferentes respecto de sus vecinos más próximos y no tienen relación con la escena.

La interpretación cualitativa no necesariamente es subjetiva, sino que en todo caso, es un proceso no referido a una escala o patrón de medida previamente definido. La evaluación cualitativa puede ser por ejemplo de tipo booleana, es decir, la

decisión consiste en establecer la existencia o no de un patrón, o bien, en la utilidad o no de una información dada.

Al hacer una evaluación cualitativa se debe hacer uso de otras herramientas que complementen los datos obtenidos a través de la observación directa de la imagen. El análisis de la imagen de la detección de bordes, la interpretación de la distribución de contraste, la comparación de un perfil representativo y los histogramas conforman un buen ejemplo de dichas herramientas.

La evaluación cuantitativa y cualitativa aquí descritas fueron aplicadas sistemáticamente para identificar las características del filtro geométrico y llevar a cabo una comparación detallada con otros filtros, obteniendo con base en los resultados experimentales una serie de conclusiones.

En primera instancia se analiza el comportamiento que presenta el filtro Geométrico de acuerdo al número de iteraciones aplicadas a la imagen. En segundo término, el conjunto de criterios establecidos se utiliza para comparar el desempeño del algoritmo del filtro geométrico con respecto a los filtros de Lee, Frost, Kuan y sigma; en este caso las imágenes fueron procesadas con una iteración y empleando una ventana de 3 x 3 *pixeles* debido a que la comparación entre los resultados que se obtengan, éstos tienen que ser bajo los mismos parámetros de operación y porque en un filtro lo que se busca es que la reducción del ruido se lleve a cabo introduciendo el menor número de datos y en el menor tiempo posible.

En las pruebas que se hicieron se puso especial interés en las imágenes SAR, principalmente en la Seasat, ya que en ella está presente el caso típico de ruido multiplicativo. Este filtro geométrico también ha sido probado con imágenes con ruido aditivo (Pastrana, 1996).

Después de que a la imagen degradada por ruido se le aplicaron los diferentes filtros se llevaron a cabo cada uno de los pasos establecidos en los criterios de evaluación cuantitativa y cualitativa mostrando a continuación las tablas con los resultados numéricos. Dichos criterios nos indican que para la imagen original degradada por ruido su mejor resultado fue con el filtro Geométrico.

El filtro geométrico es un método altamente efectivo y conveniente en la remoción de ruido speckle, mejorando la apariencia visual y la preservación de los rasgos texturales: realza la agudeza de bordes, conserva los finos detalles y no suprime patrones de líneas de pocos *pixeles* de extensión.

Los resultados indican que el filtro geométrico muestra un desempeño superior a los otros métodos evaluados, debido a que reduce el speckle pero preservando los bordes, esto quiere decir que a medida que se reduce el speckle los bordes se mantienen, aunado a ello sólo se requiere especificar el número de

iteraciones, mientras que en otros se llega a necesitar el tamaño de la ventana y hasta un tercer parámetro como la varianza global a-priori.

Finalmente, con base en los resultados obtenidos es posible afirmar que el filtro geométrico es un método de restauración útil como paso previo al reconocimiento de patrones (Pastrana, 1996). De todo esto es que se consideró utilizar el filtro geométrico para realizar la restauración de las imágenes de radar que se utilizarán en el presente trabajo de tesis.

También se llevaron a cabo pruebas referentes a la detección de bordes de la imagen original degradada por ruido speckle, así como a las imágenes ya filtradas por los diferentes algoritmos. Se obtuvieron a la vez los histogramas de cada una de las imágenes, a la vez que para examinar un perfil específico para todas las imágenes se tomó en cuenta el renglón 260 de la imagen Seasat, esto debido a la información de bordes representativos que contiene, además de que atraviesa regiones con textura suave.

Empleando el operador de Kirsch, fueron producidas las imágenes de detección de bordes correspondientes a cada una de las imágenes original y filtradas.

Los resultados de las imágenes que se obtuvieron relativas a las evaluaciones, así como las tablas con los datos obtenidos, se muestran en el Anexo B.

### 3.1.4. Modelos de Texturas.

Una representación diferente de una imagen digital, a partir de la cual es posible deducir un par de conceptos adicionales a los ya planteados, sería graficar en un espacio de tres dimensiones una banda cualquiera de una imagen multiespectral, colocando en el plano  $x$ - $y$  la posición de cada pixel y en el eje  $z$  su valor, obteniendo de esta manera una superficie. Se tendría una superficie suave donde los valores de los *pixeles* cambian poco y si en una zona de la imagen cambian los valores de los *pixeles* en forma relativamente rápida, se tendría como consecuencia una superficie rugosa, donde la sucesión de crestas y valles, así como su amplitud y alternancia, determinarían la rugosidad del área.

**Textura:** Manifestación espacial organizada de un arreglo local de tonos de *pixeles* de la imagen.

Entonces, es posible esquematizar en primera aproximación lo siguiente:

textura rugosa	———	superficie accidentada
textura suave	———	superficie aplanada

Esta es una generalización de la idea de textura que se tiene en cuanto al relieve de una superficie sólida. La textura es local, puede cambiar de un lugar a otro

de la imagen y depende de la escala a la cual se le observe; también se manifiesta diferente de banda a banda de la imagen multispectral.

La textura ha encontrado una amplia aplicación en el procesamiento de imágenes. Algunos de los métodos de análisis de texturas son la clasificación de imágenes basada en su textura, la segmentación de una imagen en regiones de textura homogéneas, extracción de información de contornos de superficies a partir de un *gradiente de textura*, sintetizar texturas que se parezcan a imágenes naturales para diversas aplicaciones y restaurar imágenes con texturas similares a partir de una base de datos, entre otras (Karu et al., 1996).

### Modelos de texturas.

El análisis de texturas juega un papel importante en la visión humana, en la visión por computadora, el reconocimiento de patrones y procesamiento digital de imágenes.

La textura se utiliza para detectar o distinguir entre los objetos y las regiones pertenecientes a una imagen, así como también para inferir perspectivas, orientación de superficies y formas en escenas en tres dimensiones y para diferenciar entre varias regiones.

Han sido desarrollados varios métodos (Jixian et al., 1996) utilizados para la descripción de ciertas características de la textura de una imagen, sin embargo, muchas de estas características texturales han sido extraídas solamente en una escala y se han ignorado los atributos a varias escalas de la textura que puede estar contenida en una imagen.

Para modelar una textura es necesario caracterizar del valor de los *pixeles*, es decir, de los tonos o niveles de gris, así como de la relación espacial que existe entre ellos. Esto implica que realmente se trata de una estructura de dos niveles, donde el primer nivel tiene que ver con la especificación de las propiedades locales y el segundo nivel con la especificación de la organización entre los mismos tonos. Lo que se desea es que con los métodos para modelar texturas se puedan analizar cada uno de estos aspectos (Haralick, 1979), por lo que han surgido aproximaciones estadísticas para la medición y caracterización de la textura en una imagen.

Una manera para percibir a una textura como una distribución de la frecuencia espacial es verla como la cantidad de bordes que se presentan por unidad de área.

TESIS CON  
FALLA DE ORIGEN

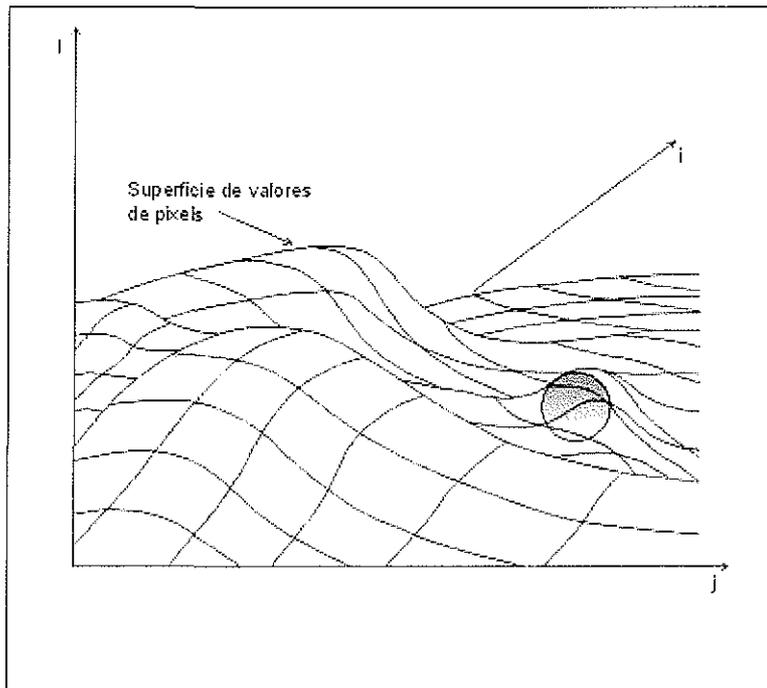


Fig. 3.10. Imagen digital vista como una superficie (textura).

El comprender una textura es un aspecto importante del análisis de una imagen, debido a que las texturas contienen información que puede ser usada en la detección y el reconocimiento de objetos. Para estimar la textura contenida en una imagen existen varios modelos o métodos, algunos de los más comunes son: el modelo autorregresivo, método por estimadores lineales, método por matriz de co-ocurrencia, métodos estadísticos (Campos aleatorios de Markov) y el modelo de divergencia, este último será especificado con mayor detalle más adelante en la sección 3.2.

#### Modelo Autorregresivo.

El modelo autorregresivo es una manera de usar estimaciones lineales de un tono de gris de un píxel dados los tonos de gris contenidos en una vecindad, a modo de caracterizar una textura. Para texturas gruesas, todos los coeficientes serán similares y para texturas finas, los coeficientes tendrán grandes variaciones.

Un punto a favor de una aproximación por frecuencia espacial para texturas es la familiaridad que se tiene con el concepto. Sin embargo, uno de los problemas inherentes es respecto a la calibración de los tonos de gris de la imagen. Los procedimientos no son invariantes bajo una transformación monótonica de niveles de gris, para compensar esto una cuantización de probabilidad puede ser empleada. En cambio, la utilidad de una aproximación por un elemento estructural es que se

enfatan los aspectos del contorno de los tonos. El inconveniente que este método presenta es que solamente puede hacerse esto en imágenes binarias.

#### Método por estimadores lineales.

La importancia de utilizar una aproximación por estimadores lineales de autorregresión es por ser fácil de usar este estimador, de modo tal que este sintetiza las texturas a partir de cualquier estimador dado inicialmente. En este caso, la estimación por autorregresión es suficiente para capturar todo acerca de una textura, sin dejar de tomar en cuenta que la textura puede ser caracterizada como micro texturas (Haralick, 1979).

#### Método por matriz de co-ocurrencia.

La matriz de co-ocurrencia se basa en estadísticas de segundo orden, que consiste en la relación espacial de pares de *pixeles* en una imagen digital de texturas.

Esta matriz de co-ocurrencia estima con que frecuencia los pares de niveles de gris de los *pixeles*, que están separados por cierta distancia y posicionados a lo largo de una cierta dirección, ocurren en una imagen digital de textura. Muy frecuentemente la matriz de co-ocurrencia no es utilizada directamente, pero ciertos descriptores basados en ella son calculados. El problema que se presenta es que no se capturan los aspectos del contorno de los niveles, como en texturas compuestas de grandes áreas.

#### Métodos estadísticos.

Diferentes modelos estadísticos y estructurales han sido utilizados en la literatura para generar y clasificar texturas. Entre los métodos estadísticos encontramos estudios basados en características y estudios basados en modelos estocásticos, como por ejemplo modelos de series en el tiempo, fractales, modelos de mosaicos aleatorios y campos aleatorios de Markov (MRF<sup>7</sup>).

### 3.1.5. Descriptores de Texturas.

Para un análisis más profundo de la naturaleza de una imagen es necesario estudiar la frecuencia con que ocurren los posibles pares de niveles de gris en una posición relativa, esto se lleva a cabo mediante la matriz de co-ocurrencia de los niveles de gris de la imagen. Esta matriz puede usarse para calcular características locales o globales de la imagen, directa y eficientemente en el dominio espacial. Si la matriz se aplica a secciones locales de la imagen tendremos características locales y si se aplica en toda la imagen se obtendrán características globales.

---

<sup>7</sup> *MRF* es el acrónimo de Markov Random Field

Para explicar la matriz de co-ocurrencia, también conocida como el segundo momento estadístico de niveles de gris, supongamos que  $f$  es la imagen a analizar con  $k$  niveles de gris  $z_1, z_2, \dots, z_k$ , y sea  $\delta = (\Delta x, \Delta y)$  un desplazamiento, será  $M_\delta$  la matriz de dimensión  $k \times k$ , cuyo elemento  $(i, j)$  indica el número de veces que un pixel, con un nivel de gris  $z_i$ , ocurre en la posición relativa  $\delta$  con respecto a un pixel que tiene un nivel de gris  $z_j$ ,  $1 \leq i, j \leq k$ . Por ejemplo, si  $f$  es

$$\begin{matrix} 1 & 1 & 2 & 2 \\ 0 & 2 & 2 & 1 \\ 0 & 0 & 2 & 1 \\ 1 & 0 & 0 & 1 \end{matrix}$$

y  $\delta$  es  $(1, 0)$ , entonces la matriz de co-ocurrencia, de los pares de  $f$ ,  $M_\delta$  es

$$\begin{matrix} 2 & 1 & 2 \\ 1 & 1 & 1 \\ 0 & 2 & 2 \end{matrix}$$

Nótese que la dimensión de  $M_\delta$  depende sólo del número de niveles de gris de  $f$  y no del tamaño de la imagen; en este caso se tienen 3 niveles. Los elementos cerca de la diagonal principal de  $M_\delta$  corresponden a pares de niveles de gris que son iguales, mientras que los elementos que están alejados de la diagonal principal corresponden a los pares que son diferentes.

Sea  $N_\delta$  el número total de pares de *pixeles* en  $f$  en la posición relativa  $\delta$ , este número es menor que el número total de *pixeles* de la imagen, ya que si  $(x, y)$  se encuentra cerca del borde, entonces  $(x + \Delta x, y + \Delta y)$  tal vez esté fuera de ella. Por lo que se debe tener en cuenta que el número de pares siempre es menor al número de *pixeles*.

Ahora bien, en la matriz  $P_\delta = M_\delta / N_\delta$  (i.e., si dividimos cada elemento de  $M_\delta$  por  $N_\delta$ ), el elemento  $(i, j)$  de  $P_\delta$  es una estimación de la probabilidad de que un par de *pixeles* en la posición relativa  $\delta$  tenga el par de niveles de gris  $(z_i, z_j)$ . A  $P_\delta$  se le llama matriz de co-ocurrencia de niveles de gris.

Las matrices  $P_\delta$  para varios desplazamientos de  $\delta$  proporcionan información útil acerca de la distribución espacial de los niveles de gris en  $f$ . Puesto que  $P_\delta$  depende de  $\delta$  es posible entonces detectar, con ayuda de esta matriz, la presencia de un patrón de textura en la imagen. Por ejemplo, si  $f$  consiste de líneas largas y orientadas en alguna dirección, entonces la distribución de los valores en  $P_\delta$  dependerá de la longitud y ángulo de  $\delta$ .

Si la dirección de  $\delta$  no es importante, podemos usar matrices  $\bar{P}$  que son el promedio de las  $P_\delta$ 's o matrices  $\bar{M}$  que son la suma de las  $M_\delta$ 's para grupos de desplazamientos de una longitud dada en varias direcciones. Por ejemplo, si  $f$  es la imagen de 4 x 4 vista anteriormente y sumamos los desplazamientos (1,0) (0,1), (-1,0) y (0,-1), entonces la matriz combinada  $\bar{M}$  es

$$\begin{matrix} 8 & 4 & 4 \\ 4 & 6 & 5 \\ 4 & 5 & 8 \end{matrix}$$

nótese que la matriz  $\bar{M}$  es simétrica, ya que el grupo de direcciones usado es simétrico.

En la práctica, matrices que corresponden a desplazamientos grandes no son de utilidad porque a medida que  $\delta$  crece los pares de tonos de gris separados por  $\delta$  llegan a estar decorrelacionados; así que para propósitos prácticos no necesitamos usar desplazamientos  $\delta$  que estén por encima de la distancia en donde los niveles de gris de la imagen permanezcan correlacionados, o mayor que el tamaño de la estructura de la cual está compuesta  $f$ . De hecho, la  $P_\delta$  más importante es la que comúnmente tiene una  $\delta$  de longitud igual a uno.

$$\delta \leq \sqrt{2}$$

Haralick (1979) propuso un número de descriptores que pueden usarse para caracterizar la matriz de co-ocurrencia  $P_\delta$ , el objetivo es que estos descriptores capturen algunos rasgos de la textura de una imagen como la homogeneidad o periodicidad, entre otros. Haralick a ido a la par en esto al sugerir sus 14 descriptores texturales, que incluyen información teórica y características estadísticas que aparentemente no tienen un significado de apreciación visual (Gotlieb y Kreyszing, 1990).

Los 14 descriptores de Haralick pueden ser clasificados en cuatro grupos:

**GRUPO 1.** Manifiestan rasgos visuales de texturas: Homogeneidad, Contraste y Correlación.

**GRUPO 2.** Basados en estadísticas: Varianza, Diferencia Inversa, Suma de Promedios, Suma de varianzas y Diferencia de Varianzas.

**GRUPO 3.** Basados en teoría de la información: Entropía, Suma de Entropías y Diferencia de Entropías.

**GRUPO 4.** Basados en medidas de la información de correlación: Coeficiente de correlación máxima.

A continuación se especifican algunos de ellos :

1.- Contraste

$$C = \sum_{i=1}^k \sum_{j=1}^k (i-j)^2 P_{\delta}(i, j) \quad (3.1.5-1)$$

2.- Probabilidad Máxima

$$P = \max_{i,j} (P_{\delta}(i, j)) \quad (3.1.5-2)$$

3.- Entropía

$$\varepsilon = - \sum_{i=1}^k \sum_{j=1}^k P_{\delta}(i-j) \log P_{\delta}(i, j) \quad (3.1.5-3)$$

4.- Homogeneidad

$$H = \sum_{i=1}^k \sum_{j=1}^k P_{\delta}^2(i, j) \quad (3.1.5-4)$$

El primer descriptor es una medida del contraste de  $f$ , tiene poco contraste cuando la concentración de la diagonal principal de  $P_{\delta}$  es alta y el contraste es alto para el caso contrario. El segundo descriptor indica cual es el par con valores  $(i,j)$  más probables en  $f$ . El tercero es una medida del desorden, logrando su valor más alto cuando los elementos  $P_{\delta}(i,j)$  son todos iguales, por lo tanto la concentración de la diagonal principal es alta y el valor de la entropía es bajo; todo lo contrario es para el caso del cuarto descriptor, éste es bajo cuando los elementos  $P_{\delta}(i,j)$  son todos iguales y alto cuando todos son diferentes.

La entropía desde el punto de vista de las imágenes sigue siendo una medida del desorden, pero este desorden está basado en los valores de los *pixeles* de la imagen, esto es, qué tanto difieren los valores de los *pixeles* entre ellos; esto sirve para darnos una idea de las texturas que contiene la imagen. En el caso de texturas rugosas, los valores de los *pixeles* no van a estar muy alejados, esto quiere decir que el desorden no es grande, por lo tanto el valor de la entropía es pequeño; en cambio, en las texturas finas los valores de los *pixeles* están muy alejados presentando un desorden grande, dando con esto un valor de entropía alto (Chavira, 1996).

### 3.2. Modelo de Divergencia.

Ahora bien, las texturas que puedan estar contenidas en una imagen multispectral también se pueden medir mediante un operador de divergencia. Antes de definir a este operador se introducen las siguientes definiciones básicas:

**Campo escalar** .- Es la asociación que se tiene de un punto  $(x,y,z)$  con un *número* de una función dada por  $f(x,y,z)$ , en un dominio de un sistema cartesiano tridimensional.

**Campo vectorial** .- Es la asociación que se tiene de un punto  $(x,y,z)$  con un *vector* dado por  $u(x,y,z)$ , en un dominio de un sistema cartesiano tridimensional.

**Campo estacionario** .- Se llama así al campo, escalar o vectorial, que no depende del tiempo.

En el modelo de texturas que se realiza utilizando un operador de divergencia una imagen multiespectral es modelada como un campo vectorial de  $n$ -dimensiones, donde  $n$  es el número de bandas que contenga la imagen. Esto quiere decir, que un pixel de la imagen es visto como un vector de  $n$ -dimensiones en el espacio.

Dado que las variaciones de flujo del campo vectorial que se tendría en una imagen multiespectral, se encuentran asociadas a los cambios de texturas de la imagen, el operador de divergencia es utilizado para medir el contenido de texturas. Una variación nula está relacionada a una textura suave, mientras que una textura rugosa está asociada con un cierto cambio del flujo. De este modo, un operador de divergencia es un sistema cartesiano de coordenadas de un espacio euclidiano, el cual mide la variación del flujo y, por consecuencia, la textura.

Para el caso práctico se utilizaron las tres primeras componentes de una imagen multiespectral para construir el campo vectorial (Lira y Rodríguez, 2001).

### 3.2.1. Campo vectorial de la imagen multiespectral.

Para generar el campo vectorial de una imagen multiespectral se considera una rejilla rectangular de dimensiones  $M \times N$ , la cual estará definida como el producto cartesiano:

$$\mathcal{L} \equiv \{1, \dots, M\} \times \{1, \dots, N\} \quad (3.2.1-1)$$

Se tendrá un vector de  $n$  dimensiones  $(b_1, b_2, \dots, b_n)$ , el cual representa las propiedades espectrales promedio de un CIV<sup>8</sup>, es decir, un elemento de imagen pixel de la imagen multiespectral.

El conjunto de *pixeles* que forman a una imagen multiespectral puede ser expresado como:

$$g_i = \{b_i(k,l)\}, \quad \forall i \quad (3.2.1-2)$$

<sup>8</sup> CIV es el acrónimo de Campo Instantáneo de Vista

donde  $i$  es el conjunto  $\{1,2,\dots,n\}$  que representa la colección de bandas de la imagen multiespectral y  $(k,l)$  son las coordenadas espaciales de los *pixeles* de la imagen.

Los valores que pueden tomar los *pixeles* estarán dados de acuerdo a la siguiente expresión:

$$b_i \in B \equiv \{ x \mid x \in \mathbb{N}, 0 \leq x \leq 2^m - 1 \}, \quad \forall i \quad (3.2.1-3)$$

donde para el caso de imágenes multiespectrales  $7 \leq m \leq 12$ . Ahora bien, si definimos:

$$X_i \equiv \{ x_i \mid x_i \in \mathbb{N}; 0 \leq x_i \leq 2^m - 1 \}, \quad \forall i \quad (3.2.1-4)$$

El producto cartesiano  $X^n = X_1 \times X_2 \times \dots \times X_n$  expresa el conjunto de  $n$ -ésimo orden  $(x_1, x_2, \dots, x_n)$ . Para cada  $n$ -ésimo vector  $(b_1, b_2, \dots, b_n)$  un vector  $u$  es asociado,  $u(x_1, x_2, \dots, x_n) \Leftarrow (b_1, b_2, \dots, b_n)$ , por lo que la dimensión de dicho vector  $u$  está dada por:

$$\|u\| = \left[ \sum_{i=1}^n x_i^2 \right]^{1/2} \quad (3.2.1-5)$$

El conjunto de vectores  $\{u(x_1, x_2, \dots, x_n)\}$  es entonces un campo vectorial asociado a una imagen multiespectral (Lira, 2001).

### 3.2.2. Operador de divergencia

El operador divergencia es útil para encontrar la razón de cambio que pueda tener un campo vectorial en cada una de las componentes de  $u$  en las direcciones que se tengan del sistema de ejes coordenados, para un sistema de 3 dimensiones estaría dado como:

$$\nabla = \left[ \frac{\partial}{\partial x} \hat{i} + \frac{\partial}{\partial y} \hat{j} + \frac{\partial}{\partial z} \hat{k} \right] \quad (3.2.2-1)$$

por lo que la divergencia de un campo vectorial en una imagen multiespectral está dada por

$$\nabla \cdot u = \left[ \frac{\partial}{\partial x} \hat{i} + \frac{\partial}{\partial y} \hat{j} + \frac{\partial}{\partial z} \hat{k} \right] \cdot [u_x(x, y, z)\hat{i} + u_y(x, y, z)\hat{j} + u_z(x, y, z)\hat{k}] \quad (3.2.2-2)$$

o bien,

$$\nabla \cdot u = \frac{\partial u_x(x, y, z)}{\partial x} + \frac{\partial u_y(x, y, z)}{\partial y} + \frac{\partial u_z(x, y, z)}{\partial z} \quad (3.2.2-3)$$

donde  $u = (u_x, u_y, u_z)$ .

El operador de divergencia para un campo vectorial  $u$  de  $n$  dimensiones esta definido como

$$\nabla \cdot u = \sum_{i=1}^n \frac{\partial u_{x_i}}{\partial x_i} \quad (3.2.2-4)$$

donde  $x_i$  es la coordenada  $n$ -ésima de un sistema de coordenadas de un espacio euclidiano y  $u_{x_i}$  es la componente del campo vectorial  $u = u(x_1, x_2, \dots, x_n)$  a lo largo de la dirección definida por  $x_i$ .

El flujo que se tenga en un campo vectorial se considera como la cantidad de líneas de campo que atraviezan por una unidad de área. Si definimos a esta unidad de área como  $\delta a$  y consideramos  $\hat{n}$  como un vector unitario normal al área  $\delta a$ , el flujo de un campo vectorial para una superficie  $S$  está expresado como

$$\phi = \iint_S u \cdot \hat{n} \delta a \quad (3.2.2-5)$$

Asumiendo las contribuciones del flujo  $\phi_{x_i}$ ,  $\forall x_i$  y tomando el límite cuando  $\delta x_i \rightarrow 0$ , tendríamos

$$\phi = \sum_{i=1}^n \frac{\partial u_{x_i}}{\partial x_i} \quad (3.2.2-6)$$

por lo que el operador de divergencia de un campo vectorial (3.2.2-4) puede ser obtenido por medio del flujo de un campo vectorial (Lira y Rodríguez, 2001).

### 3.3. Comparación textura-radar vs. textura-divergencia.

En el presente trabajo de tesis se han desarrollado dos modelos de texturas: uno basado en la Matriz de co-ocurrencia y el otro en el Operador de divergencia.

En el primero, el análisis de texturas se lleva cabo mediante el cálculo de la matriz de co-ocurrencia utilizando una imagen de radar SEASAT. Esta imagen siendo de radar es mono-banda.

En el segundo caso, se utiliza el operador de divergencia aplicado al campo vectorial que forma una imagen multiespectral LANDSAT.

Para la realización de las pruebas con los dos modelos de textura mencionados, se escogió una zona de la región de la Sierra de Obayos, Coahuila, debido a su riqueza en el contenido de texturas (Figura 3.11).

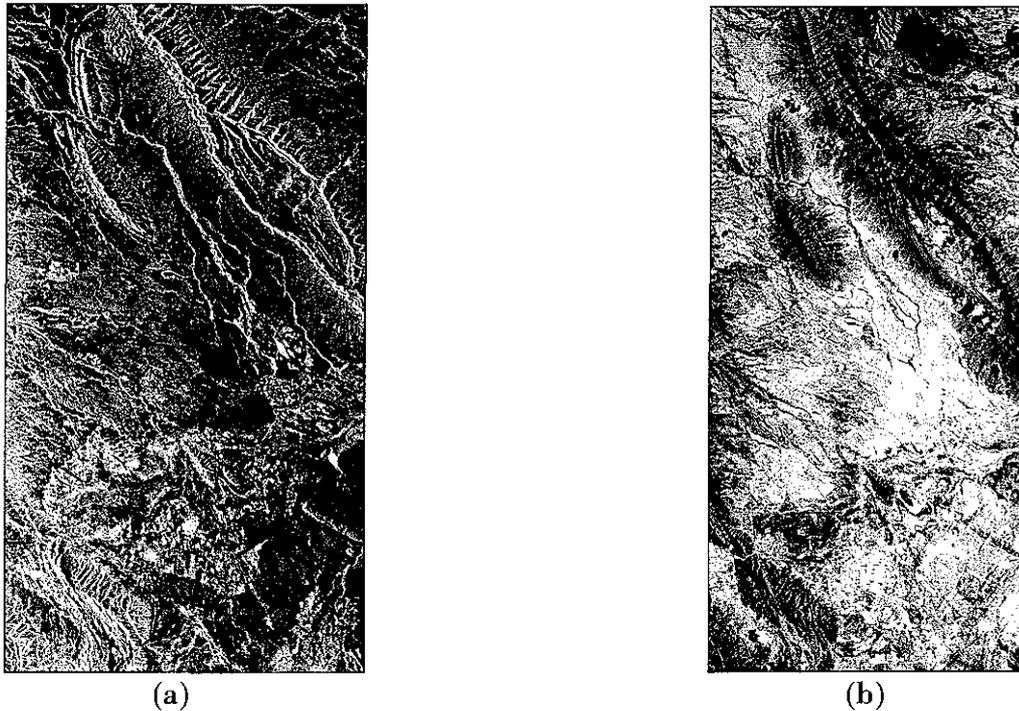


Figura 3.11. Zona de la Sierra de Obayos: (a) Imagen Seasat Filtrada y (b) Imagen Landsat.

Como se mencionó anteriormente, para realizar el análisis de texturas por medio del modelo de la matriz de co-ocurrencia se utilizó una imagen de radar Seasat, la cual es rica en texturas, el software que se utilizó fue SANDI, creado en el Laboratorio de Percepción Remota del Instituto de Geofísica, UNAM. Para evaluar la matriz de co-ocurrencia se utilizó una ventana de  $37 \times 37$  *pixeles* y las cuatro primeras direcciones del código de Freeman; el descriptor empleado para estimar el contenido de información textural de esta matriz fue el de entropía (Haralick, 1979). La Figura 3.12 muestra la imagen que se obtuvo al aplicar este modelo.

Para el análisis de textura empleando el modelo de divergencia se utilizó una imagen multiespectral LANDSAT de la misma región. Se aplicó la descomposición en componentes principales a la imagen multiespectral utilizando 6 bandas de la imagen multiespectral; de acuerdo a la varianza de las componentes, se seleccionaron las tres primeras como entradas para calcular el operador de divergencia. Para este modelo de divergencia se utilizó un algoritmo de divergencia desarrollado en el mismo Laboratorio de Percepción Remota. La Figura 3.13 muestra la imagen que se obtuvo como resultado al aplicar este modelo de divergencia.



Figura 3.12. Análisis de Textura utilizando el modelo de Matriz de co-ocurrencia en Imagen Seasat.



Figura 3.12. Análisis de textura utilizando el modelo del operador de divergencia.

TESIS CON  
FALLA DE ORIGEN

Al hacer un análisis cualitativo, como puede observarse en las imágenes que se obtuvieron por ambos métodos, cuando se utilizó el modelo de matriz de co-ocurrencia a la imagen original de radar, que contiene una riqueza en texturas, la imagen de texturas que se obtuvo del terreno es buena. Sin embargo en el segundo método, siendo un método no paramétrico y de no poseer gran diversidad de texturas en las bandas originales, al aplicar el operador de divergencia se obtiene una buena información sobre la textura del terreno, a partir de la información de todas las bandas de la imagen multiespectral, obteniéndose así un mejor análisis y resultados de las texturas que se tienen presentes en la región.

Debido a lo anterior, se decidió utilizar el mapa de texturas generado por el operador de divergencia como una variable para el modelo matemático.

# CAPÍTULO CUATRO

## MODELO MATEMÁTICO DEL PROCESO DE DESERTIFICACIÓN.

El interés central del presente trabajo de tesis es el desarrollo de un modelo matemático para el proceso de desertificación utilizando variables canónicas. Un modelo matemático es la caracterización de un proceso mediante términos matemáticos que permite la manipulación de un proceso mediante el cambio de variables que pertenecen al mismo.

### 4.1. Expansión canónica.

Una transformación canónica es una variante de la transformación Karhunen Loeve (KL). La transformación KL es una transformación de similaridad (Arfken, 1970) debido a que genera un nuevo espacio donde se tiene una nueva representación del operador de covarianza, por medio de la siguiente relación

$$K_g = AK_rA^t \quad (4.1-1)$$

donde  $K_r$ , siendo la matriz de covarianza de la imagen original, es un operador real y simétrico, y  $A$  es un operador unitario ortogonal. La transformación KL se escribe vectorialmente como

$$g(s) = A^t f(r) \quad (4.1-2)$$

donde  $A$  es una matriz cuyos renglones son los eigenvectores de  $K_f$ .

En una transformación canónica la representación del operador  $K_f$  cambia. El análisis canónico es una variante de la transformación KL, pero con un carácter más específico, pues incluye información acerca del comportamiento estadístico de las clases de patrones de la imagen multi-espectral y por lo mismo requiere de información a priori acerca de la misma. En el análisis canónico se conserva la información de las clases, pero no es una transformación unitaria, reduciéndose la dimensionalidad del espacio donde se encuentran representados los datos de la imagen. Como resultado de ello, se genera un nuevo espacio donde las clases tienen máxima separabilidad. En el análisis canónico (Lira, 2001) la transformación se define de la siguiente manera

$$g(s) = D^t\{f(r)\} \quad (4.1-3)$$

donde la matriz  $D$  ejecuta la siguiente operación

$$I = K_p^g = D^t K_p^f D \quad (4.1-4)$$

y

$$K_c^g = D^t K_c^f D \quad (4.1-5)$$

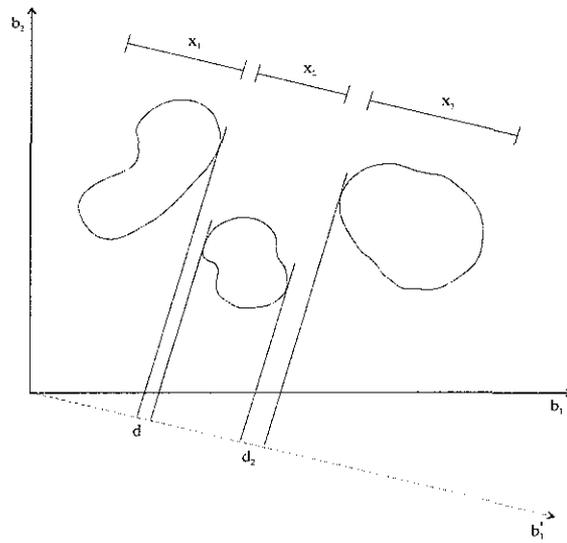
donde  $K_p^f$  es la matriz de covarianza promedio de la covarianza de cada clase y  $K_c^f$  es la matriz de covarianza entre las clases. Como un ejemplo del análisis canónico en la Figura 4.1 se observan tres clases para una imagen de dos bandas; las tres clases se separan en la primera banda del análisis canónico.

En muchas ocasiones esta separabilidad no se alcanza sobre la primera componente del análisis canónico, puede ser que persista un traslape entre clases debido al espacio donde se tienen estas clases. Y conforme el número de clases consideradas aumenta, una separabilidad completa llega a ser imposible.

En una imagen multiespectral, una representación canónica está dada por la siguiente expresión

$$Y_i(k,l) = \mu_i^Y + \sum_{j=1}^M a_{ij} X_j(k,l), \quad \forall i = 1, 2, \dots, \gamma \quad (4.1-6)$$

donde  $\mu^Y = \{\mu_1^Y, \mu_2^Y, \dots, \mu_\gamma^Y\}$  es el vector que representa la media de la imagen multiespectral  $Y = \{y_1, y_2, \dots, y_\gamma\}$  para  $\gamma$  bandas y la dimensión de la imagen es  $N \times M$  pixeles, además de que los coeficientes  $a_{ij}$  son funciones deterministas y el término  $(k,l)$  son las coordenadas de un pixel en la imagen (Lira, 2001).



TESIS CON  
FALLA DE ORIGEN

Fig. 4.1. Nube de datos para dos bandas y tres clases.

Las funciones bidimensionales  $X_j$  son las bandas por medio de las cuales una imagen está representada, las cuales son variables no-correlacionadas de media cero; para este caso en particular se están considerando tres bandas en la expansión canónica, es decir,  $X_1$ ,  $X_2$  y  $X_3$  debido a que la dimensionalidad intrínseca de una imagen Landsat es de tres.

#### 4.2. Indicadores de la desertificación.

Dentro del proceso de desertificación se experimentan diversos cambios. Uno de estos cambios se puede observar a través de la textura que se tiene en una imagen, en zonas donde se tiene una alta densidad de vegetación se puede observar que la textura es un tanto más rugosa, mientras que en zonas donde se tienen presentes zonas áridas la textura que se puede observar más bien es plana. Otro aspecto que nos muestra los cambios que se presentan por la desertificación en alguna región es el albedo, el cual es una medida de la radiación reflejada por el suelo, más adelante en este capítulo se explica con detalle lo referente al albedo, los cambios que se pueden observar a través de esta reflectividad del suelo consisten en que mientras más vegetación exista en la zona se tendrá una menor reflectividad, la cual se puede observar a través de niveles de gris oscuros en una imagen, mientras que en una zona árida y desértica donde no exista vegetación se tendrá un alto valor de reflectividad, en una imagen se puede mostrar esto como niveles de gris claros. Otra manera de observar los cambios que se experimentan en el proceso de desertificación es a través del vigor de vegetación

existente en una zona, a mayor densidad de vegetación en una región se tiene un vigor de vegetación alto y viceversa.

Ciertos indicadores para el proceso de la desertificación o de la degradación de la calidad y productividad en zonas áridas ha sido discutido por varios autores. En este trabajo de tesis el proceso de desertificación se caracteriza mediante un modelo matemático que emplea como indicadores las bandas canónicas: Albedo, Textura y Vigor de vegetación y Humedad del terreno.

Se consideraron como bandas canónicas las mencionadas en el párrafo anterior, debido a que se observó que el albedo responde a un cambio en la densidad de vegetación de una zona, es decir, a mayor densidad de vegetación se tiene menor valor en el albedo y, en el caso contrario, cuando se tiene poca e incluso un grado nulo de vegetación el albedo aumenta su valor. Así mismo, la otra banda canónica considerada es la textura, debido a que conforme cambia la concentración de vegetación en una zona la textura que se observa será diferente, un ejemplo de ello es que si la zona que se está observando es de un bosque, donde la vegetación es abundante, la textura que se tiene en la imagen es rugosa, mientras que si se estuviera observando una zona de cultivos la textura se observaría mas suavizada y si se observara una zona donde el suelo está expuesto y sin vegetación la textura que se tendrá será totalmente plana. Y por último, se ha considerado como una tercer banda canónica al vigor de vegetación y humedad del terreno debido a que el interés en particular que se tiene es resaltar zonas con ciertos grados de desertificación, por lo que esta banda canónica nos estará indicando precisamente la presencia o ausencia de vegetación en la zona, por lo que si se observa una zona con un alto grado de contenido de vegetación se tendrá un alto vigor de vegetación y viceversa. A continuación se describe el concepto de cada una de estas bandas canónicas.

#### 4.2.1. Albedo (Primera Componente Principal).

El análisis de componentes principales de una imagen multispectral genera una representación canónica en términos de un sistema de coordenadas ortonormal. Este sistema es abarcado por los eingenectores de la matriz de covarianza de la imagen multispectral. Sea  $f$  la imagen multispectral con matriz de covarianza  $K^f$ , entonces la expansión canónica estará dada por la siguiente expresión

$$g_i(k,l) = \sum_{i=1}^{\gamma} f_i(k,l)e_{ij}, \quad \forall i = 1,2,\dots,\gamma \quad (4.2.1-1)$$

donde  $g$  es la imagen multispectral generada por el análisis de componentes principales de la imagen de entrada  $f$ . Las bandas de  $g$  forman un sistema de variables no correlacionadas nombradas componentes principales.

En notación matricial la ecuación que representa a los eigenvectores  $\hat{e}_i$  y los eigenvalores  $\lambda_i$  está dada por

$$[K_f - \Lambda I]A = 0 \quad (4.2.1-2)$$

El operador  $A$  está compuesto por los eigenvectores de  $K_f$ , los cuales son linealmente independientes y están normalizados a la unidad, y  $\Lambda$  es una matriz diagonal formada por los eigenvalores de  $K_f$ . Por lo tanto, la imagen de entrada  $f$  puede ser expandida en términos del sistema de componentes principales definido por  $g$  (eq. 4.2.1-1). Se conoce que la primera componente principal es proporcional al albedo de una zona o región. Por lo que para estimar el albedo de una zona en particular puede realizarse por medio de la primera componente principal, es decir, un análisis canónico puede ser considerado para evaluar el albedo (Lira,2001).

El albedo es la razón de la cantidad de radiación electromagnética reflejada por una superficie en relación a la que incidente sobre ésta. Se expresa comunmente como un porcentaje. Simbólicamente el albedo se escribe como

$$\text{Albedo} = \frac{R_i}{S_i} \quad (4.2.1-3)$$

donde  $R_i$  es la radiación reflejada y  $S_i$  es la radiación incidente integradas para un intervalo de longitudes de onda (Robinove et al., 1981).

Los valores del albedo difieren de una localidad a otra, la textura de la superficie terrestre influye en el albedo de una zona dada, así como también la presencia de vegetación, nubes, lluvias, nieve, entre otros. Una característica común es que, en la degradación de zonas áridas, tiende a incrementarse la cantidad de radiación reflejada, generalmente debido a que la densidad de vegetación disminuye y el suelo queda expuesto.

Por lo que en una zona cubierta con vegetación el albedo es menor que en una zona árida y con poca vegetación, debido a que la reflectividad que presenta el suelo es mayor a la que se tiene sobre la vegetación, como se puede observar en la Tabla 4.1.

Tabla 4.1. Valores de albedo para diferentes objetos.

Objeto	Albedo
Vegetación	0.10
Nieve	0.60
Suelo	0.30
Zona urbana	0.20

Para obtener este indicador se aplicó la descomposición en componentes principales a la imagen multiespectral Landsat utilizando 6 bandas; seleccionándose la primer componente como la banda canónica del albedo. En la Figura 4.2 se muestra la imagen de la banda canónica del albedo, donde se puede observar que las zonas con mayor reflectividad son áreas que presentan cierto grado de degradación del suelo, es decir áridas o semi-áridas. De acuerdo a la imagen se puede observar la relación que existe entre los niveles de gris de la imagen y el albedo, esto es para un valor pequeño del albedo le corresponde un nivel de gris oscuro y, viceversa, para un valor alto del albedo le corresponde un nivel de gris claro.

#### 4.2.2. Textura (Operador de divergencia).

Como se mencionó en el capítulo anterior la Textura es la manifestación espacial organizada de un arreglo local de tonos de pixels de la imagen. Uno de los métodos de análisis de texturas es la segmentación de una imagen en regiones de textura homogéneas o bien, la extracción de información de contornos de superficies a partir de un *gradiente de textura*, para este caso en particular se utilizó el operador de divergencia.



TESIS CON  
FALLA DE ORIGEN

Fig. 4.2. Imagen de la banda canónica del Albedo.

Debido a que en un mapa de texturas se logra una diferenciación de las regiones contenidas en la imagen, para zonas donde no exista una gran concentración de vegetación o se encuentre en condiciones áridas, la textura obtenida se apreciará como una textura suave. Es por esta razón que se ha seleccionado como banda canónica a un mapa de texturas.

En la Figura 4.3 se muestra la banda canónica de textura utilizada para el desarrollo del modelo. Se puede observar en la imagen que para regiones con texturas suaves, donde no se tiene mucha vegetación, se tiene presentes niveles de gris claro y, viceversa, para regiones donde se presenta una textura más gruesa, con presencia de vegetación, los niveles de gris que le corresponde son oscuros.



Fig. 4.3 Imagen de la banda canónica de Texturas.

#### 4.2.3. Vigor de vegetación y Humedad del terreno (TSAVI).

El análisis de la vegetación y la detección de cambios en los patrones de vegetación son la clave para realizar una valoración de este recurso natural, así como su monitoreo. Tanto el análisis como la detección de vegetación son elementos básicos en las aplicaciones de la percepción remota.

El verdor de la vegetación tiene una interacción muy distintiva con la energía de las regiones visible e infrarroja cercana del espectro electromagnético. En la región visible, los pigmentos o la clorofila de las plantas son la causa de una fuerte absorción de energía, mientras que en la región infrarroja ocurre una interacción diferente debido a que la energía en esta región es diseminada, es decir, no es absorbida. Es este contraste el que ha sido el centro de una gran cantidad de esfuerzos para desarrollar índices cuantitativos de condiciones de vegetación.

Los índices de vegetación pueden ser clasificados en tres grupos: 1) índices de vegetación basados en la dirección de incidencia de la radiación electromagnética, 2) índices basados en la distancia e 3) índices basados en una transformación ortogonal.

Algunos de los principales índices de vegetación son los siguientes:

1) Índices basados en la dirección de incidencia de la radiación electromagnética.

- **Cociente de Índice de Vegetación (RATIO<sup>1</sup>):** Fue propuesto con la finalidad de separar el verdor de la vegetación del fondo del suelo utilizando imágenes Landsat MSS y se obtiene simplemente dividiendo los valores de la reflectancia contenidos en la banda infrarroja cercana (NIR<sup>2</sup>) y la banda roja (RED), expresándose de la siguiente manera

$$\text{RATIO} = \frac{\text{NIR}}{\text{RED}} \quad (4.2.3-1)$$

El resultado de este cociente indica el contraste entre las bandas; debido a esto los problemas de variación de iluminación, como resultado de la topografía del terreno, son minimizados.

- **Diferencia Normalizada de Índice de Vegetación (NDVI<sup>3</sup>):** Produce un índice de vegetación que separa el verdor de la vegetación de la brillantez del fondo del suelo utilizando los datos digitales de una imagen Landsat. Se expresa como la diferencia entre las bandas NIR y RED normalizadas por la suma de éstas, es decir

$$\text{NDVI} = \frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED})} \quad (4.2.3-2)$$

Este es el índice de vegetación más comunmente utilizado debido a que presenta minimiza los efectos topográficos, a la vez que genera una escala lineal de medición, y reduciendo los errores causados por una división entre cero.

---

<sup>1</sup> *RATIO*, tomado del nombre en inglés 'Ratio Vegetation Index'

<sup>2</sup> *NIR* es el acrónimo de Near Infrared

<sup>3</sup> *NDVI* es el acrónimo de Normalized Difference Vegetation Index

2) Índices basados en la distancia.

El principal objetivo de este tipo de índices es cancelar el efecto de la brillantez del suelo en casos donde la vegetación es poco densa, por lo que esto es particularmente importante en ambientes áridos y semi-áridos.

- **Índice de Vegetación Perpendicular (PVI<sup>4</sup>):** Este índice utiliza la distancia perpendicular, a partir de las coordenadas de un sistema cartesiano de cada pixel, a una recta llamada línea de suelo, la cual se obtiene al realizar una regresión lineal entre las bandas NIR y RED. Para la obtención de esta distancia perpendicular, se requiere de los siguientes cuatro pasos:

- a. Se determina la ecuación de la recta 'línea de suelo' mediante una regresión lineal entre las bandas RED y NIR, la cual está expresada como

$$Rg5 = a_0 + a_1Rg7 \quad (4.2.3-3)$$

donde Rg5 es una posición Y en la línea de suelo, Rg7 es la coordenada X correspondiente,  $a_1$  es la pendiente de la recta y  $a_0$  es la ordenada al origen de esta misma recta.

- b. Se encuentra la ecuación de la recta perpendicular a la línea de suelo de la siguiente manera

$$Rp5 = b_0 + b_1Rp7 \quad (4.2.3-4)$$

donde Rp5 es la reflectividad de la banda RED y Rp7 es la reflectividad de la banda NIR y  $b_1$  es la pendiente de la recta perpendicular ( $b_1 = -1/a_1$ ).

- c. Se obtiene la intersección de estas dos líneas, donde las coordenadas estarían dadas como

$$Rgg5 = \frac{b_1a_0 - b_0a_1}{b_1 - a_1} \quad (4.2.3-5)$$

$$Rgg7 = \frac{a_0 - b_0}{b_1 - a_1} \quad (4.2.3-6)$$

- d. Y para encontrar la distancia entre el punto de intersección y el pixel con coordenadas (Rp5, Rp7) se tiene que

$$PVI = \sqrt{(Rgg5 - Rp5)^2 + (Rgg7 - Rp7)^2} \quad (4.2.3-7)$$

- **Índice de Vegetación de Ajuste al suelo (SAVI<sup>5</sup>):** Este índice intenta minimizar los efectos del fondo del suelo sobre la vegetación incorporando una constante como factor de ajuste L en el denominador del índice NDVI. Este factor L varía de

<sup>4</sup> PVI es el acrónimo de Perpendicular Vegetation Index

<sup>5</sup> SAVI es el acrónimo de Soil - Adjusted Vegetation Index

acuerdo con las características de reflectancia del suelo. Para un área con baja vegetación se sugiere utilizar un factor L de 1.0, mientras que para niveles intermedios puede considerar un valor de L de 0.5 y de 0.25 para zonas con alta densidad de vegetación. Este índice está dado como

$$SAVI = \frac{\rho_{NIR} - \rho_{RED}}{(\rho_{NIR} + \rho_{RED} + L)} \cdot (1 + L) \quad (4.2.3-8)$$

donde  $\rho_{NIR}$  es la banda infrarroja cercana,  $\rho_{RED}$  es la banda rojo visible y L es el factor de ajuste al suelo.

- **Índice Transformado de Vegetación de Ajuste al suelo (TSAVI<sup>6</sup>):** El índice transformado de vegetación de ajuste al suelo fue definido por Baret (Baret et al., 1991), el cual está dado por la siguiente expresión:

$$TSAVI_1 = \frac{a(NIR - aRED - b)}{RED + aNIR - ab} \quad (4.2.3-9)$$

donde NIR es la reflectancia en la banda infrarroja cercana, RED es la reflectancia en la banda roja visible, a es la pendiente de la línea del suelo y b es la intersección de la línea del suelo, obtenidas a partir de una regresión lineal entre las bandas RED y NIR. Baret propone una nueva transformación a este índice para ser utilizado en regiones áridas o semi-áridas, el cual está expresado como

$$TSAVI_2 = \frac{a(NIR - aRED - b)}{RED + aNIR - ab + 0.08(1 + a^2)} \quad (4.2.3-10)$$

El valor de 0.08 es un factor de corrección aditivo para minimizar el efecto de la brillantez del fondo del suelo.

Debido a lo anterior, fue que se seleccionó al índice TSAVI<sub>2</sub> como otra de las bandas canónicas para el modelo matemático, el cual fue obtenido utilizando la regresión lineal y el índice con las bandas 4 (RED) y 7 (NIR) de la imagen multiespectral Landsat TM, debido a la información contenida en ellas (Jackson; 1983). La figura 4.4 muestra la imagen resultante para la banda canónica de vigor de vegetación y humedad del terreno. En esta imagen podemos observar que la relación que existe entre los niveles de gris y el índice de vigor de vegetación es que para regiones con una alta densidad de vegetación se tienen niveles de gris claro, mientras que para regiones con escasa o nula vegetación se tienen niveles de gris oscuro, nótese la inversión de contraste con la imagen resultante para la variable canónica del albedo.

<sup>6</sup> TSAVI es el acrónimo de Soil - Adjusted Vegetation Index



Fig. 4.4 Imagen de la banda canónica de vigor de la vegetación y humedad del terreno.

#### 4.3. Combinación de indicadores.

Lo que se busca con el presente modelo matemático es separar en clases una región de una imagen, donde dichas clases representan diferentes grados de desertificación en esa zona. Utilizando para ello las tres bandas canónicas: Albedo, Textura y Vigor de la Vegetación y Humedad del Terreno, buscando así obtener la máxima separación entre las clases relativas a la desertificación. En la Figura 4.5. se muestra una imagen falso color (RGB<sup>7</sup>) tomando las bandas canónicas de Textura, Vigor de vegetación y humedad del terreno y Albedo, respectivamente.

---

<sup>7</sup> RGB es el acrónimo de Red-Green-Blue



Fig. 4.5. Imagen falso color utilizando las bandas canónicas de Textura, Vigor de vegetación y humedad del terreno y Albedo.

Se asegura que al realizar una clasificación utilizando como entradas estas tres bandas canónicas, se obtendrá una buena separabilidad entre las regiones que representan diferentes niveles de desertificación de la zona.

Se llevó a cabo una clasificación, con las tres bandas canónicas empleando el algoritmo de isocluster, clasificación por análisis de cúmulos (Lira, 2001), empleando los siguientes parámetros: mínimo número de clases=7, máximo número de clases=7, número de iteraciones=30, imagen falso color RGB. Cada una de las clases representa un nivel o grado de desertificación del terreno, obteniéndose la imagen que se muestra en la Figura 4.5, debido a que no se encontró en la literatura un criterio universal para definir los grados de desertificación, se adoptó la escala mostrada en la Figura 4.6.

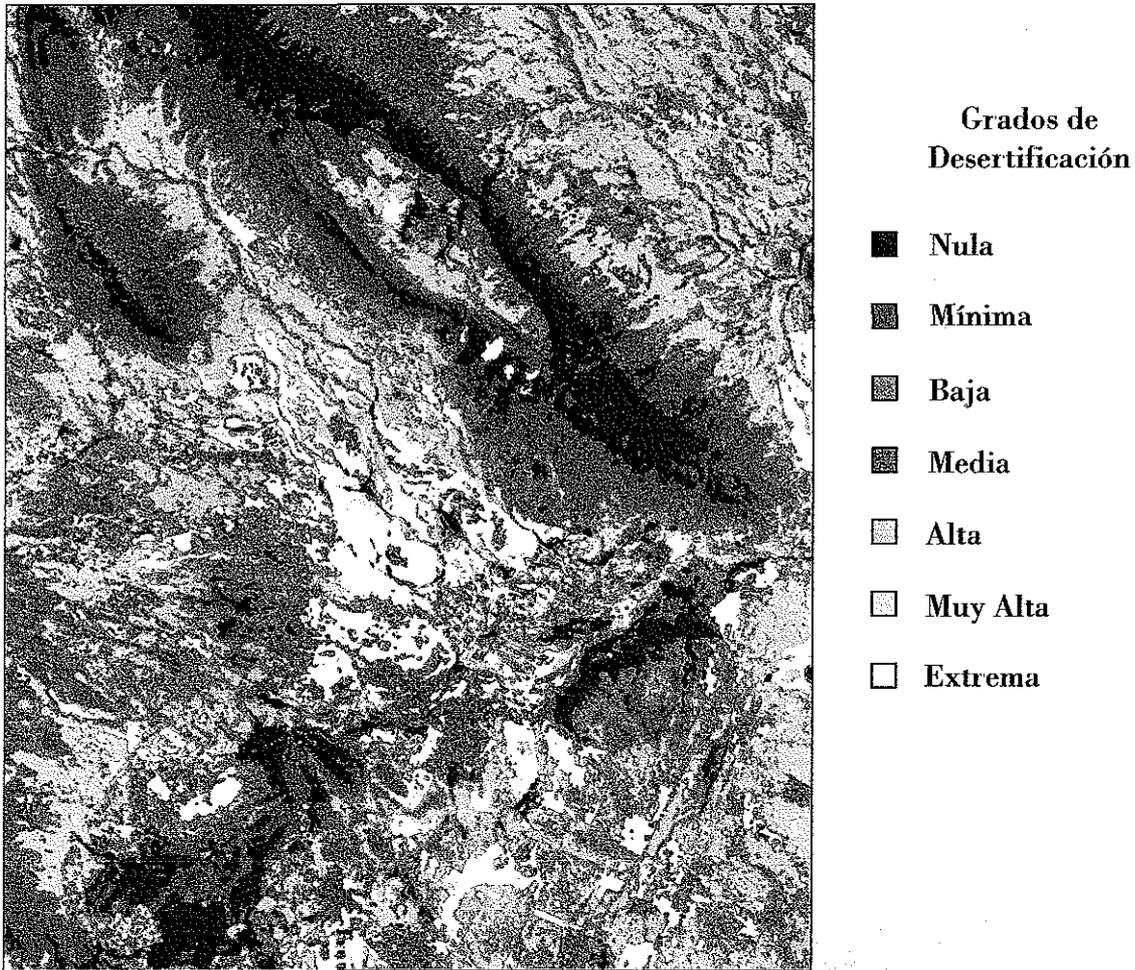


Fig. 4.6. Imagen obtenida mediante el modelo matemático para el proceso de desertificación, indicando grados de desertificación.

Al hacer un análisis cualitativo de la imagen que se obtuvo con la clasificación empleando las bandas canónicas se puede observar que se tiene como resultado una buena separabilidad de clases, la cual es satisfactoria.

Así mismo se puede llevar a cabo una validación de la imagen resultante en base a los aspectos geográficos que se presentan en la zona de estudio.

Si se comparan el mapa de niveles de desertificación obtenido con un espaciograma de la imagen falso color Landsat TM obtenida en 1993 por el INEGI<sup>8</sup> mostrada en la Figura 4.7, se podrá observar de manera cualitativa que se tienen resultados óptimos.

<sup>8</sup> INEGI es el acrónimo de Instituto Nacional de Estadística, Geografía e Informática.

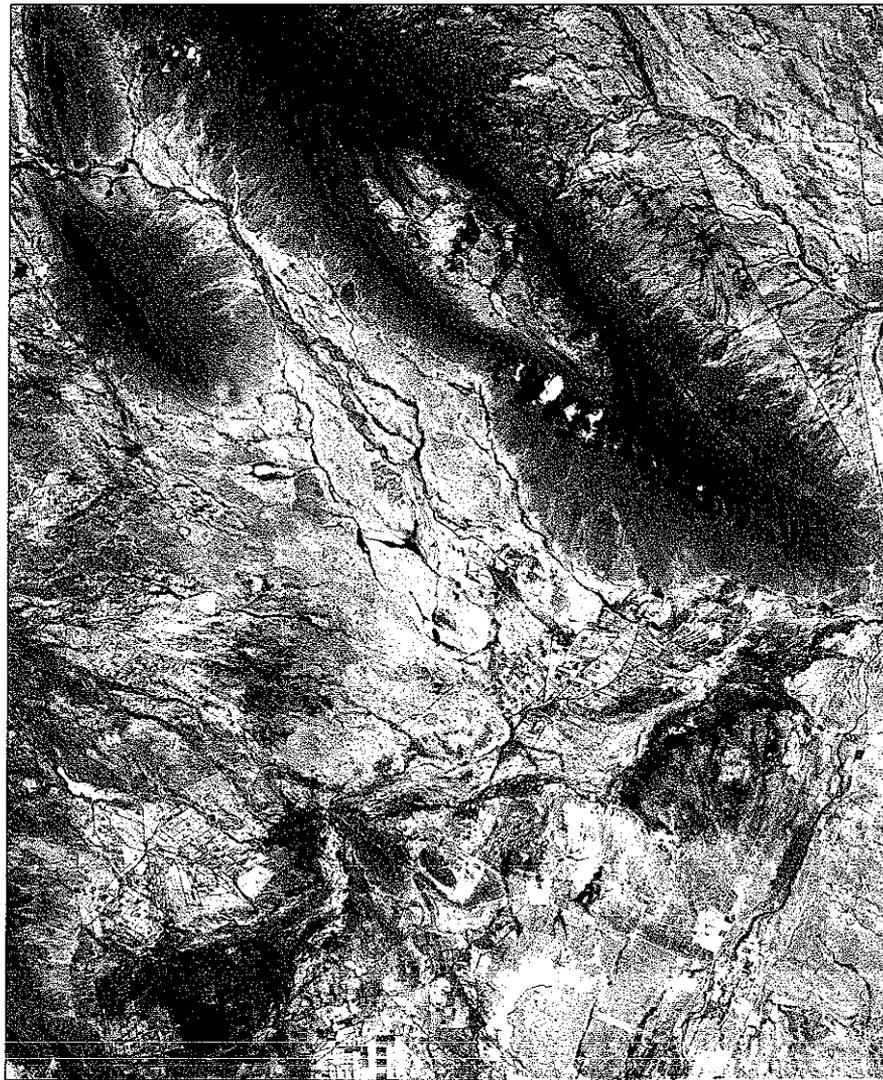


Fig. 4.7. Espaciomapa, imagen Landsat TM 1993, INEGI.

Donde el criterio que se utiliza para este tipo de espaciomapas es el siguiente:

Color Rojo: Zona de vegetación verde.

Color azul tenue: Zona de localidad urbana.

Color negro: Zona de presas y lagos profundos, cuando éstos no son tan profundos se consideran un color azul.

Color rosa: Zona de cultivos de riego.

Color blanco: Zona de Cultivos de temporal.

La región de la Sierra de Obayos, Coahuila, de la imagen que se trabajó y analizó se encuentra a una altitud de entre los 450 y 1400 msnm<sup>9</sup>. Desde el punto de vista geológico de la región el tipo de roca mayoritario que se tiene presente es la roca

<sup>9</sup> msnm es el acrónimo de metros sobre el nivel del mar.

sedimentaria. De acuerdo a las condiciones climáticas se tiene que en las llanuras y bajadas de menor altitud, entre 1000 y 1400 msnm, se tiene un clima seco y semiseco, tanto cálido como semicálido. En las zonas de los lomeríos, bajadas y llanuras entre los 500 y 1000 msns el clima es menos cálido y se descende por terrenos y zonas de clima semicálido y cálido, donde la temperatura promedio anual es superior a los 22° C y la temperatura promedio mensual es de 30° C. Se tiene una precipitación promedio anual de 300 mm y la región de la Sierra de Obayos se encuentra situada en la cuenca de la Presa Río Salado.

Todas estas condiciones climatológicas ayudan a la presencia de vegetación halófila en las partes altas de la Sierra como elemento predominante, con la presencia también de matorral desértico y pastizal, aún en condiciones de menor sequedad, sin embargo se tienen zonas con nula presencia de vegetación. El uso potencial que se da a la tierra es para tracción animal continua y no es totalmente apta para la agricultura.

Si se toma en cuenta todas estas consideraciones geográficas de la región y se comparan con los resultados obtenidos en la imagen de niveles de desertificación se podrá complementar la validación de los resultados observando que en las zonas con mayor altitud se tendrá la presencia de mayor vegetación, así como en los lugares donde se tiene la presencia de cultivos de riego; mientras que en las zonas de los terrenos, menor a los 500 msnm, es donde se tienen mayor ausencia de vegetación, como se muestra en la Tabla 4.2 (INEGI, 1999). En el siguiente capítulo se amplía la discusión de los resultados obtenidos mediante un análisis cuantitativo más detallado.

**Tabla 4.2. Validación de niveles de desertificación para diferentes zonas.**

Coordenadas Latitud - Longitud	Altitud (msnm)	Temperatura °C	Vegetación	Nivel de Desertificación
27° 31' - 101° 31'	1050	18°	Matorral desértico	Nula
27° 26' - 101° 42'	750	22°	Matorral desértico	Baja
27° 20' - 101° 33'	550	33°	Pastizal	Alta
27° 14' - 101° 32'	500	33°	Sin vegetación	Extrema



# CAPÍTULO CINCO

## RESULTADOS.

En el capítulo anterior se mostró el mapa final de niveles de desertificación, obtenido con el modelo matemático propuesto empleando variables canónicas. A continuación se discutirán los resultados, analizándose ciertas regiones del mapa y comparándolas con la imagen de falso color. Las zonas se han seleccionado de acuerdo a la presencia de ciertos niveles del proceso de desertificación en la imagen, la Figura 5.1 muestra cada una de las regiones seleccionadas.

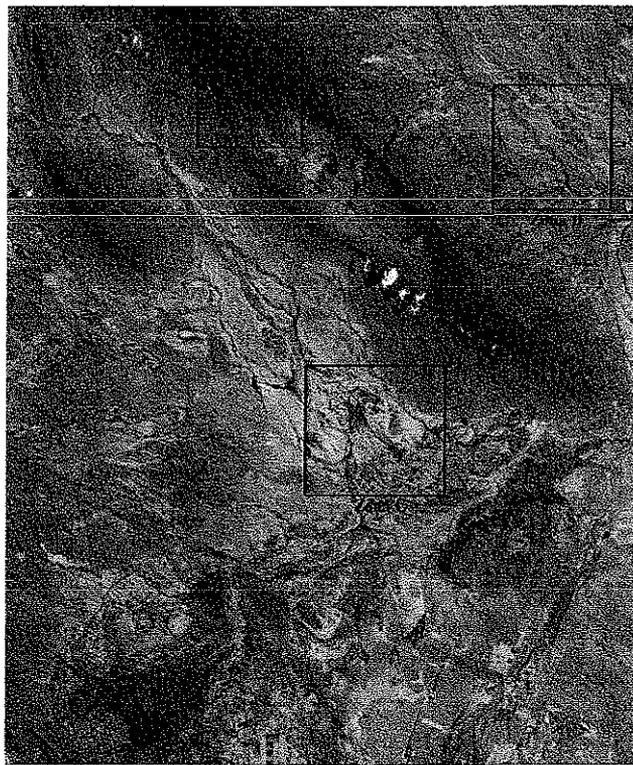
En la zona A se tienen presentes niveles mínimos y nulos de desertificación, es decir, se tiene una alta concentración de vegetación en la zona, poca reflectividad del suelo y una textura no plana.

La región delimitada en la zona B se seleccionó debido a que se tienen presentes desde niveles de desertificación bajos, medios y altos, hasta la presencia de un nivel máximo de desertificación.

En la zona C se tiene la presencia en su mayoría de niveles de desertificación extrema, aunque también se encuentran presentes en menor número otros niveles de desertificación.



(a)



(b)

TESIS CON  
FALLA DE ORIGEN

Figura 5.1. Zonas A, B y C seleccionadas para el análisis de los resultados obtenidos:  
(a) Mapa de niveles de desertificación y (b) Imagen falso color.

En la Tabla 5.1 se muestran los valores de niveles de gris de las variables canónicas para ciertos grados de desertificación. Con los cuáles se puede verificar la relación existente entre los niveles de gris presentes en cada una de las variables canónicas, para los diferentes niveles de desertificación.

Tabla 5.1. Niveles de gris de las variables canónicas para tres grados de desertificación.

desertificación	Variables Canónicas		
	Textura	Albedo	TSAVI
nula	180-255	0-25	233-255
media	23-144	74-133	90-166
máxima	0-24	240-255	0-24

En las imágenes de la Figura 5.2 se muestra una ampliación de cada una de estas zonas, tanto para la imagen de falso color como para la imagen del mapa de niveles de desertificación.

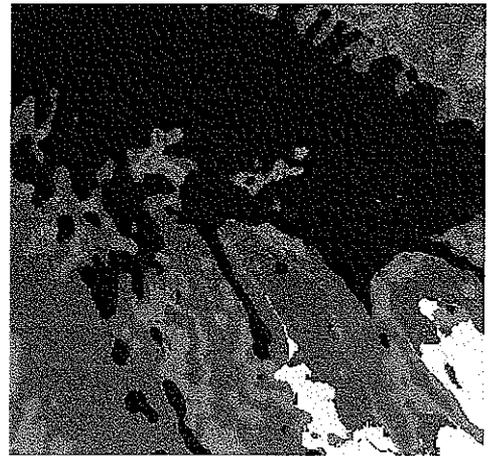
Como se puede observar en cada una de las imágenes presentadas en la Figura 5.2. la clasificación que se tiene de los niveles de desertificación es muy buena, dado que al comparar de manera cualitativa las imágenes de falso color, que se encuentran del lado izquierdo, con las imágenes obtenidas del mapa de niveles de desertificación del lado derecho, se puede observar que se tienen bien demarcadas las zonas con diferente nivel de desertificación.

En la zona A, de la imagen de falso color, se puede observar que la mayor parte de ésta se trata de una región no desertificada, es decir, se tiene una alta concentración de vegetación, lo cual se ve reflejado en el mapa de niveles de desertificación, donde dichas zonas corresponden a las que se muestran en color verde oscuro, indicando así que se trata de un nivel de desertificación nulo. Las regiones que muestran un nivel de desertificación menor en la imagen falso color se muestran en tonos diferentes en el mapa.

En la zona B se tiene presente una región de transición del proceso de desertificación, que se refleja en su mayoría con niveles intermedios. Como se puede observar al comparar la imagen de falso color con el mapa de niveles de desertificación, las regiones para cada nivel vuelven a corresponder con la imagen de falso color. Lo cual podemos observar también en las imágenes para la zona C, donde en su mayoría se tiene presente un nivel de desertificación extremo. Si se observa la imagen de falso color, las regiones de tono más claro son las áreas con mayor desertificación y al compararlas con el mapa de niveles de desertificación se observa que dichas regiones coinciden, o bien, que la clasificación de los niveles en la zona es congruente con lo observado en la imagen de falso color.



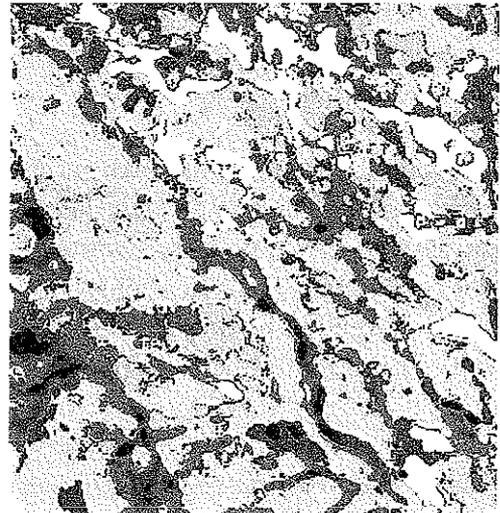
Zona A



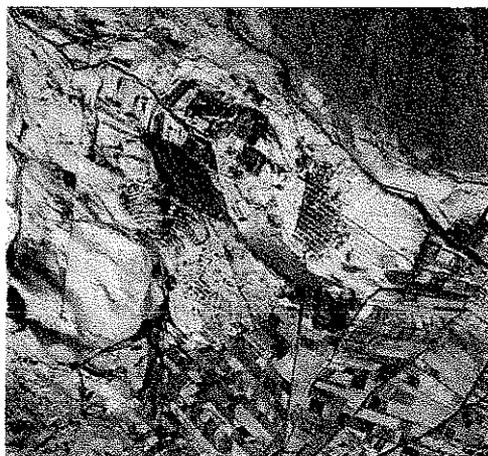
Zona A



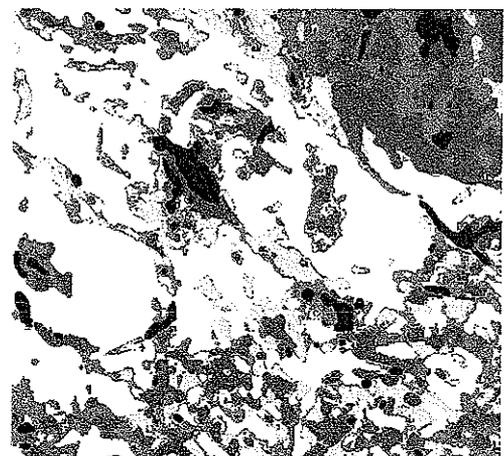
Zona B



Zona B



Zona C



Zona C

TESIS CON  
FALLA DE ORIGEN

Figura 5.2. Zonas A, B y C mostrando diferentes grados de desertificación tanto para el mapa de niveles de desertificación y la imagen falso color...

### 5.1. Correlación entre las bandas canónicas.

Los buenos resultados obtenidos se han debido a que las variables que se utilizaron en el modelo matemático de desertificación no se encuentran altamente correlacionadas entre sí, es decir, cada una de estas variable nos proporciona información suficiente y complementaria para la generación de un buen mapa de niveles de desertificación.

En la Tabla 5.2. se muestra la matriz de correlación entre las variables canónicas que se utilizaron para la generación del mapa de niveles de desertificación, de acuerdo a la siguiente relación:

Banda 1 : Variable canónica de Textura

Banda 2 : Variable canónica de Albedo

Banda 3 : Variable Canónica de Vigor de vegetación y Humedad del terreno.

Tabla 5.2. Matriz de correlación entre las variables canónicas para el mapa de niveles de desertificación.

	Textura	Albedo	Vigor de Vegetación
Textura	1.000	0.035	0.017
Albedo	0.035	1.000	-0.504
Vigor de Vegetación	0.017	-0.504	1.000

Como se puede observar en la Tabla 5.1. los valores que se tienen de correlación entre las variables canónicas es bajo, aunque cabe hacer mención que la correlación entre la variable canónica de Albedo y la variable canónica de Vigor de Vegetación y Humedad del Terreno presenta un valor relativamente alto, esto es debido a que cuando se quiere obtener el índice de vegetación de una zona se está considerando no sólo la respuesta a la radiación de la vegetación sino también la del suelo, y de la misma manera al obtener el albedo se observa que el suelo responde con un valor mayor de reflectividad que la luz, es por esto que la información obtenida de una imagen, como un indicador del proceso de desertificación, por medio del índice de vegetación y el albedo se encuentre hasta cierto punto relacionada. El signo menos que se tiene en el valor de la correlación entre la variable canónica del Albedo y el Vigor de Vegetación solo nos indica que se tiene una cierta inversión de contraste entre ambas variables canónicas.

### 5.2. Distancia de Jeffries Matusita (JM).

La distancia Jeffries Matusita (JM) es una medida de la separabilidad estadística que existe entre un par de clases. Es decir, es una medida de la diferencia

promedio entre las funciones de densidad de dos clases. Esta distancia está definida por la siguiente expresión:

$$J_{ij} = [2(1-e^{-\alpha})]^{1/2} \quad (5.2-1)$$

donde

$$\alpha = \frac{1}{8}(\mu_i - \mu_j)^T \left( \frac{k_i + k_j}{2} \right)^{-1} (\mu_i - \mu_j) + \frac{1}{2} \log_e \left[ \frac{|(k_i + k_j)/2|}{(|k_i| \cdot |k_j|)^{1/2}} \right] \quad (5.2-2)$$

siendo  $\mu_i$  y  $\mu_j$  las medias de las clases  $i$  y  $j$ , y  $k_i$  y  $k_j$  son las matrices de covarianza de cada una de las clases.

Al aplicar un algoritmo para la distancia de JM al mapa de niveles de desertificación, el cual consta de 7 clases, se obtuvieron los valores de separación entre las mismas que se muestran en la Tabla 5.3. Un valor de cero nos indica que no existe separación entre un par de clases, o bien, que se trata de la misma clase; sin embargo, cuando se tiene una total separabilidad estadística entre clases, el valor que se obtiene es de 2. Para este caso podemos observar que todos los valores obtenidos se encuentran sobre un valor de 1.57, lo cual indica que la separación existente entre las clases o niveles de desertificación que se obtuvieron es muy buena. Al obtener un promedio para la distancia JM en este caso se tiene un valor de 1.80, en términos generales se dirá entonces que en el mapa de niveles de desertificación se tiene una buena separación entre las clases, o bien, entre los niveles de desertificación presentes en la imagen de la zona de interés.

Tabla 5.3. Distancias de JM entre las clases obtenidas en el mapa niveles de desertificación.

niveles de desertificación	nulo	mínimo	bajo	medio	alto	muy alto	máximo
nulo	0.00	1.58	1.98	2.00	2.00	1.82	1.90
mínimo	1.58	0.00	1.95	2.00	1.60	1.68	2.00
bajo	1.98	1.95	0.00	1.57	1.69	1.91	1.82
medio	2.00	2.00	1.57	0.00	1.59	1.63	1.59
alto	2.00	1.60	1.69	1.59	0.00	1.57	2.00
muy alto	1.82	1.68	1.91	1.63	1.57	0.00	1.86
máximo	1.90	2.00	1.82	1.59	2.00	1.86	0.00

TESIS CON  
 FALLA DE ORIGEN

# CAPÍTULO SEIS

## CONCLUSIONES.

En las últimas décadas se han presentado diversos avances tecnológicos, un ejemplo de ello son las imágenes generadas por satélites donde se puede apreciar en ellas una alta calidad, una amplia visión sinóptica y buena resolución espacial. Las ventajas que se presentan por su carácter digital y multiespectral es que permite hacer un registro de los datos en la computadora con rapidez de análisis, así como el poder aplicar diversos procesos para resaltar y cuantificar los datos de interés.

El campo de aplicación de la percepción remota es muy vasto, en años recientes ha crecido el interés de aplicar las imágenes de satélite en la cartografía y la valoración de recursos forestales, identificación de claros por talas y detección de cambios en uso de la tierra; en la agricultura, es útil para la identificación de tipos de cultivos, predicción e inventario de cosechas, estimación de la humedad del suelo, densidad y cobertura de la vegetación, entre muchas otras aplicaciones.

Un problema presente en nuestro país es el fenómeno del proceso de desertificación, el cual no está fuera del alcance de la percepción remota. En este trabajo de tesis se vió que con la ayuda de la percepción remota, utilizando imágenes de satélite y empleando un conjunto de variables canónicas, es posible obtener un mapa de niveles de desertificación a partir de una imagen multiespectral.

Se utilizó una imagen Landast de la zona de la Sierra de Obayos, Coahuila, así como una imagen de radar Seasat de la misma zona. La imagen de radar tuvo que ser filtrada para eliminar el ruido que contenía, para lo cual se utilizó un filtro geométrico

obteniéndose muy buenos resultados; para ello se hizo un análisis de la calidad de la imagen resultante y una comparación con los resultados obtenidos mediante otros filtros. Esta imagen fue utilizada para obtener una imagen de texturas de la región, sin embargo finalmente no se usó la imagen de radar debido a que se observó que una imagen de textura con mejores resultados se obtenía utilizando una imagen multiespectral.

Una de las variables canónicas que se utilizó fue la textura. En primer lugar se obtuvo por medio del descriptor de la matriz de co-ocurrencia empleando la imagen de radar y un segundo método fue mediante un operador de divergencia empleando la imagen multiespectral. Se hizo un análisis y una comparación cualitativa entre los resultados obtenidos siendo el segundo método el mejor.

Una segunda variable canónica es el albedo, la cual se obtuvo mediante la descomposición en componentes principales de la imagen multiespectral y tomándose sólo la primera componente. La tercera variable canónica es el índice de vigor de vegetación y humedad del terreno, para el cual se empleó el índice de vegetación de ajuste al suelo transformado definido por Baret, debido a que este índice es usado en regiones áridas o semi-áridas, empleando las bandas roja e infrarroja de la imagen multiespectral.

Como se observó en el capítulo anterior, la correlación existente entre las imágenes de textura, albedo y vigor de vegetación y humedad del terreno es baja, lo cual indica que se puede realizar una buena expansión canónica entre estas variables. El modelo matemático para el proceso de desertificación presentado en este trabajo de tesis emplea estas tres variables canónicas para generar un mapa de niveles de desertificación de la zona, mediante una clasificación de análisis de cúmulos utilizando las variables canónicas.

El mapa de niveles de desertificación obtenido presenta una muy buena separación de clases, se utilizaron para este caso siete clases o niveles de desertificación. Se plantean niveles de desertificación con un grado nulo, mínimo, bajo, medio, alto, muy alto y extremo. Al hacer un análisis y una comparación cualitativa del mapa de niveles obtenido y de una imagen falso color de la misma zona, se observó que la clasificación arroja resultados de manera satisfactoria.

Se puede concluir que la información contenida en las variables canónicas de textura, albedo y vigor de vegetación y humedad del terreno, al no estar altamente correlacionadas y clasificarlas por análisis de cúmulos, nos da como resultado un mapa de niveles de desertificación óptimo.

# CAPÍTULO SIETE

## REFERENCIAS.

ACUÑA, C., 1992. Texture Modeling Using Gibbs Distributions. *Graphical Models and Image Processing*. Vol. 54, No. 3, pp. 210-222.

ALPARONE, L., BARONTI, S. y GARZELLI, A., 1995. A Hybrid Sigma Filter for Unbiased and Edge-Preserving Speckle Reduction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1409-1411.

ARFKEN, G., 1970. *Mathematical Methods for Physicists Academic Press*

BARET, F. Y GUYOT, G., 1991. Potentials and Limits of Vegetation Indices for LAI and APAR Assessment. *Remote Sensing of Environment*, Vol. 35, pp. 161-173.

BARRINGER, T.H. y ROBINSON, V.B., 1981. Stochastic Models to Cover Class Dynamics. *Proceeding, XV International Symposium on Remote Sensing of Environment*, Ann Arbor, Michigan.

CAPPELLINE, V., CONSTANTINIDES, A.G. y EMIANI, P., 1978. *Digital Filter and Their Applications. Academic Press.*

CHAVIRA, D., 1996. Evaluación de la Complejidad (Heterogeneidad) de una Imagen. Tesis de Licenciatura, Escuela de Ciencias de la Electrónica, BUAP.

- CIESIN Thematic Guides, 1996. Land Degradation and Desertification. [www.ciesin.org/TG/LU/degrad.html](http://www.ciesin.org/TG/LU/degrad.html)
- COINER, J.C., 1981. Using Landsat to Monitor Changes in Vegetation Cover Induced by Desertification Processes. *International Symposium on Remote Sensing of Environment*. 14 th. Ann Arbor Mich. Proceedings.
- CORNNERS, R.W., TRIVEDI, M.M. y HARLOW, CHA., 1984. Segmentation of a High-Resolution Urban Scene Using Texture Operators. *Computer Vision, Graphics, and Image Processing*, Vol. 25, pp. 273-310.
- CRIMMINS, T. R., 1985. Geometric Filter for Speckle Reduction. *Applied Optics*, Vol. 24, No. 10, pp. 1438-1443.
- DE ALBA, E. y REYES, M., 1998. El País: Contexto Físico, Parte 1.
- DE LA TORRE, J., 1984. Un Modelo del Proceso de Desertificación en un Ecosistema Semiárido Mediante Datos Digitales Multiespectrales Landsat. Tesis de Maestría, Universidad Iberoamericana, México, D.F.
- DESCOMBES, X., MOCTEZUMA, M., MAÎTRE, H. Y RUDANT, J., 1996. Coastline Detection by a Markovian Segmentation on SAR Images. *Signal Processing*, Vol. 55, pp. 123-132.
- DEWALE, P., WAMBACO, P. y OOSTERLINK, A., 1989. Speckle Reduction Techniques for SAR Images. *Technical Report, ESA/ESTEC*, No. 8072/88/NL/PP(SC).
- DREGNE, H.E., 1976. Desertification: Symptom of a Crisis. Quoted in Handbook of Desertification Indicator Based on The Science Association's Nairobi Seminar on Desertification (Ed.: P. Reining). AAAS, Washington, D.C. 141 p.p.
- DURAND, J., GIMONET, B. y PERBOS, J., 1987. SAR Data Filtering for Clasification. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 6E-25, pp. 629-637.
- ENVI, Version 3.2., 1999. The Environment for Visualizing Images: User's Guide. Research Systems, Software=Vision, pp.594.
- ESCALANTE, B., BERNARD, J. y DE RIDDER, H., 1995. Multidimensional Characterization of the Perceptual Quality of Noise-Reduced Computed Tomography Images. *Journal of Visual Communication and Image Representation*, Vol. 6., No 4, pp. 317-334.
- FLOYD, F. y SABINS, JR, 1978. Remote Sensing: principles and interpretation. W. H. Freeman and Company, San Francisco.

- FROST, V.S., STILES, J., SHANMUGAN, K. y HOLTZMANN, J., 1982. A Model For Radar Images and Its Applications to Adaptive Digital Filtering of Multiplicative Noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-4, pp.157-166.
- GLANTZ, M. y ORLOVSKY, N., 1986. Desertification: Anatomy of a Complex Environmental Process. In *Natural Resources and People: Conceptual issues in Interdisciplinary Researches*, ed. K.A. Dahlberg and J.W. Bennet, 213-29. Boulder, CO: Westview Press.
- GONZALEZ, R. y WINTZ, P., 1987. *Digital Image Processing. Second Edition*, Addison-Wesley Publishing Company.
- GOTLIEB, C. y KREYSZIG, H., 1990. Texture Descriptors Based on Co-ocurrence Matrices. *Computer Vision, Graphics, and Image Processing*, Vol. 51, pp. 70-86.
- HARALICK, R.M., 1979. Statistical and Structural Approaches to Texture. *IEEE*, Vol.67, pp. 786-804.
- HELLDEN, U., 1988. Desertification Monitoring: Is The Desert Encroaching?, *Desertification Control Bulletin*, Vol. 17, pp. 8-12.
- HUANG, T.S., 1981. *Two-Dimensional Digital Signal Processing. Vol. 42 and 43*, Springer-Verlag.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 1994. *Manual del Sistema de Información Geográfica*. SPRING, pp. 1.2-1.5 y 1.14-1.22.
- INEGI, 1999. *Medio Ambiente y Recursos Naturales: Suelos*. Instituto Nacional de Estadística, Geografía e Informática.
- IZQUIERDO, E., 2001. Image based rendering using rational filters. Editor(s): Banissi, E., Khosrowshahi, F., Sarfraz, M., Ursyn, A. *Information Visualisation. Proceedings. Fifth International Conference on*, pp. 311 - 316
- JAIN, A., 1989. *Fundamentals of Digital Image Processing*. Prentice Hall Information and System Sciences Series.
- JIXIAN, Z., DEREN, L. y JIAN, L., 1996. Energy Representation Based Multiscale Approach to Image Texture. *ICSP'96, IEEE*, pp. 1146-1150.
- KARU, K., JAIN, A.K. y BOLLE, R.M., 1996. Is there any Texture in the Image? *ICPR'96, IEEE* 1015-4651/96, pp. 770-774.

- KIRSCH, R., 1971. Computer Determination of the Constituent Structure of Biomedical Images. *Computers and Biomedical Research*, Vol. 4, No. 3, pp. 315-328.
- KRUGMANN, H., 1996. Toward Improved Indicators to Measure Desertification and Monitor The Implementation of the Desertification Convention. [www.idrc.ca/books/focus/794/krugmann.html](http://www.idrc.ca/books/focus/794/krugmann.html)
- KUAN, D.T., SAWCHUCK, A.A., STRAND, T.C. y CHAVEL, P., 1985. Adaptive Noise Smoothing Filter For Images With Signal – Dependent Noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-7, No. 2, pp. 165-167.
- LEE, J.S., 1981a. Speckle Analysis and Smoothing of Synthetic Aperture Radar Images. *Computer Graphics and Images Processing*, Vol. 17, pp. 29-32.
- LEE, J.S., 1981b. Refined Filtering of Image Noise Using Local Statistics. *Computer Graphics and Images Processing*, Vol. 15, pp. 380-389.
- LEE, J.S., 1983. Digital Image Smoothing and the Sigma Filter. *Computer Vision, Graphics, and Image Processing*, Vol. 24, pp. 255-269.
- LEE, J.S., (1986). Speckle Suppresion and Analysis for Synthetic Aperture Radar Images. *Optical Engineering*, Vol. 25, No. 5, pp 636-643.
- LEE, J.S. y JURKEVICH, J., 1989. Segmentation of SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 27, No. 6, pp. 674-680.
- LI, S. Z., 1989. Markov Random Field Modeling in Computer Vision. Ed. Springer.
- LILLESAND, T. y KIEFER, R., 1987. Remote Sensing and Image Interpretation. University of Wisconsin, John Wiley & Sons.
- LIRA, J., 1987. La Percepción Remota: Nuestros Ojos Desde el Espacio. Fondo de Cultura Económica, México D.F.
- LIRA, J., 2001. Introducción al Tratamiento Digital de Imágenes. Fondo de Cultura Económica, México D.F. (En imprenta)
- LIRA, J. y LANDGRAVE, R., 1992. Sistema de Análisis Digital de Imágenes. v. 2.0, *Revista SELPER*, Vol 8.
- LIRA, J. y RODRÍGUEZ, A., 2001. A Divergence Operator to segment Texture from Multi-spectral Images. *Urban 2001 Workshop*, Rome, Italy. (En publicación)
- LOPES, A., TOOZI, R. y NERRY, E., 1990. Adaptive Speckle Filters and Scene

- Heterogeneity. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 28, No. 6, pp. 992-1000.
- MARTIN, F.J. y TURNER, R., 1993. SAR Speckle Reduction and Statistical Adaptive Speckle Filtering in SAR Images. *International Journal of Remote Sensing*, Vol. 14, No. 9, pp. 1759-1774.
- MASTIN, G.A., 1985. Adaptive Filter for Digital Image Noise Smoothing: An Evaluation. *Computer Vision, Graphics, and Image Processing*, Vol. 31, pp. 103-121.
- MEDELLÍN – LEAL, F., 1978. La Desertificación en México. Ed. UA – SL, SLP, México.
- METTERNICHT, G.I. y FERMONT, A., 1997. Spectral Unmixing and Mapping of Surface Features Related to Soil Erosion. Curtin University of Technology, School of Surveying and Land Information, *IEEE*, 0-7803-3836-7/97, pp. 95-97.
- OJALA, T., PIETIKÄINEN, M. y SILVEN, O., 1992. Edge-Based, Texture Measures for surface Inspection. Department of Electrical Engineering, university of Oulu, SF-90570 Oulu, Finland. *IEEE*, 0-8186-2915-0/92, pp. 594-598.
- OLSEN, S., 1993. Estimation of Noise in Images: An Evaluation. *CVGIP: Graphical Models and Images Processing*, Vol. 55, No. 4, pp. 319-323.
- ORTIZ, C.A. y ANAYA, G.M., 1982, Metodología para la Evaluación y Cartografía de la Desertificación en México. Colegio de Posgraduados de Chapingo, México. Reporte Interno.
- PASTRANA, R., 1996. Restauración de Imágenes Digitales: Eliminación de Ruido por Medio de un Filtro Geométrico. Tesis de Licenciatura, Escuela de Ciencias de la Electrónica, BUAP.
- PEDDLE, D.R. y FRANKLIN, S.E., 1991. Image Texture Processing and Data Integration for Surface Pattern Discrimination. *Photogrammetric Engineering and Remote Sensing*, Vol. 57, pp. 413-420.
- PELAG, S., 1978. Iterative Histogram Modifications, 2. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-8, No. 7, pp. 555-556.
- PICKUP, G. y CHEWINGS, V.H., 1988. Forecasting Patterns of Soil Erosion in Arid Lands from Landsat MSS Data. *International Journal of Remote Sensing*, Vol. 9, No. 1, pp. 69-84.
- PRATT, W., 1991. Digital Image Processing. Second Edition, John Wiley & Sons, Inc.
- RAMSTEIN, G. y RAFFY, M., 1989. Analysis of the Structure of Radiometric

Remotely-Sensed Images. *International Journal of Remote Sensing*, Vol. 10, pp. 1049-1073.

RAPP, A., 1974. A Review of Desertization in Africa-Water, Vegetation and Man. Reprint of *SIES Report* No. 1, 1974 in: Lunds Universitets Naturgeografiska Institution, Rapporter Och Notiser, Vol. 39 (1978), pp. 77.

REEP, T. y DU BUF, H., 1993. A review of Recent Texture Segmentation and Feature Extraction Techniques. *CVGIP: Image Understanding*, Vol. 57, No. 3, pp. 359-372.

RICHARDS, J., 1986. Remote Sensing Digital Image Analysis: An Introduction. Springer-Verlag.

RICHARDS, J.A. y JIA, X., 1999. Remote Sensing Digital Image Analysis: An Introduction. Third Revised and Enlarge Edition. Springer.

ROBINOVE, C., CHAVEZ, S., GEHRING, D. y HOLMGREN, R., 1981. Arid Land Monitoring using Landsat Albedo Difference Images. *Remote Sensing of Environment*. Vol. 11, pp. 133-156.

ROSENFELD, A. y KAK, A., 1982. Digital Picture Processing (Computer Science and Applied Mathematics). Second Edition, Volume 1, Academic Press, Inc.

ROZANOV, B.G., 1977. Degradation of Arid Lands in the World and International Cooperation in Desertification Control. *Pchvovedenie* Vol. 8, pp. 5-11.

SEMARNAT/INEGI, 1999. Estadísticas del Medio Ambiente, México 1997 / Informe de la Situación General en Materia de Equilibrio Ecológico y Protección al Ambiente, Semarnap, Subsecretaría de Recursos Naturales.

SERRA, J., 1982. Image Analysis and Mathematical Morphology. Academic Press, London.

TANSEY, K.J. y MILLINGTON, A.C., 1998. Remote Sensing of Desert Surface Processes and Properties using Multi-temporal Radar Imagery. *IEEE*, 0-7803-4403-0/98, pp. 1348-1350.

ULABY, F.T., MOORE, R.K. y FUNG, A.K., (1986). Microwave Remote Sensing Active and Passive. Vols I, II, III, Artech House. Washington.

UNCOD A/CONF 74/36, 1977. Plan of Action to Stop Desertification. *Report on the UN Conf. on Desertification*, Nairobi.

UNCOD A/CONF 74/2, 1977. World Map of Desertification. *Doc. of the UN Conf. on Desertification*, Nairobi.

WALKER, A.S. y ROBINOVE, C.J., 1981. Annotated Bibliography of Remote Sensing Methods for Monitoring Desertification. US Geological Survey, Va. 22304, USA.

[www.usgs.gov/Earthshots](http://www.usgs.gov/Earthshots) for Earthshots, 5th ed., 14 August 1999, from the EROS Data Center of the U.S. Geological Survey, A Bureau of the U.S. Department of the Interior.



## ANEXO A.

## CORRECCIÓN GEOMÉTRICA, REGISTRO DE IMÁGENES Y LOCALIZACIÓN.

Hay dos técnicas que pueden ser utilizadas para corregir los diferentes tipos de distorsión geométrica presentados en una imagen digital. Una de estas técnicas es para modelar la naturaleza y magnitud de las fuentes de distorsión. Esta técnica es efectiva cuando los tipos de distorsión y el movimiento relativo entre el sensor y la escena están bien caracterizados, tales como los causados por la rotación de la Tierra. La segunda técnica depende de que se establezca una relación entre el direccionamiento  $(i,j)$  de los pixels en una imagen y su coordenada correspondiente sobre la tierra (en un mapa). Estas relaciones pueden ser usadas para corregir la geometría de la imagen independientemente del tipo de distorsión. Este procedimiento es el más comúnmente utilizado y, como una técnica, es independiente de la plataforma usada para la adquisición de los datos.

## A.1. Uso del mapeo polinomial para la corrección de imágenes.

Se debe asumir en este procedimiento que se tiene disponible un mapa de la región correspondiente a la imagen, que esté correctamente referido a un sistema de coordenadas geográficas. Se definen dos sistemas cartesianos de coordenadas como se muestra en la Figura A.1. Un sistema describe la ubicación de los puntos en el mapa  $(x,y)$  y el otro sistema de coordenadas define la localización de los pixels en la imagen  $(u,v)$ .

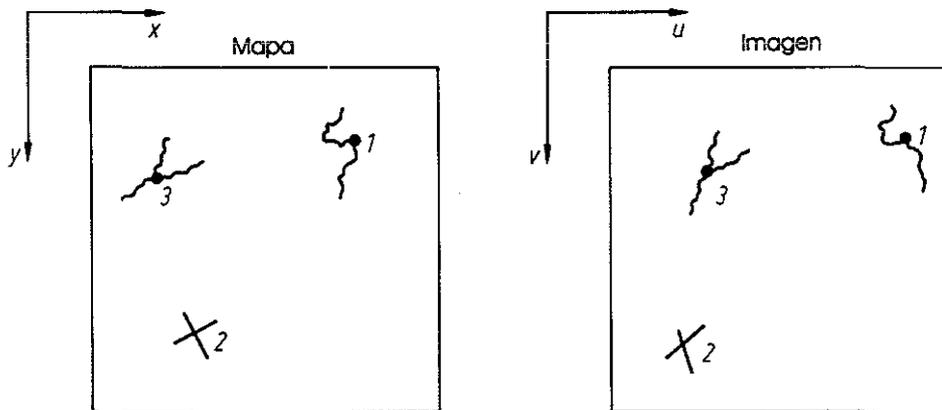


Fig. A.1. Sistema de Coordenadas definido para la imagen y el mapa, junto con la especificación de puntos de control.

Ahora supongamos que los dos sistemas de coordenadas pueden estar relacionados por medio de un par de funciones de mapeo  $f$  y  $g$ , de modo que

$$u = f(x,y) \quad (1.1-1)$$

$$v = g(x,y) \quad (1.1-2)$$

Si estas funciones son conocidas, entonces podríamos localizar un punto en la imagen conociendo su posición en el mapa, o viceversa. Aunque el proceso es muy directo, hay algunas dificultades prácticas, una es cuando no se conocen de manera explícita las funciones de mapeo y, en segundo caso, al hacerlo estos puntos pueden no corresponder exactamente con un punto en la imagen; en este caso algunas formas de interpolación pueden ser requeridas.

## A.2. Mapeo polinomial y puntos de control del terreno.

Como las formas explícitas para las funciones de mapeo en (1.1-1 y 2) no son conocidas, generalmente estas funciones son consideradas como un simple polinomio de primero, segundo o tercer grado. Por ejemplo, para el caso de un polinomio de segundo orden, tendríamos:

$$u = a_0 + a_1x + a_2y + a_3xy + a_4x^2 + a_5y^2 \quad (1.2-1)$$

$$v = b_0 + b_1x + b_2y + b_3xy + b_4x^2 + b_5y^2 \quad (1.2-2)$$

Si los coeficientes  $a_i$  y  $b_i$  fueran conocidos, entonces el mapeo polinomial podría ser utilizado para relacionar cualquier punto en el mapa con el punto correspondiente en la imagen. Sin embargo, la mayoría de las veces estos coeficientes no son conocidos. Los valores de los coeficientes pueden ser estimados identificando ciertos rasgos o características en el mapa que también pueden ser identificadas sobre la imagen. Estas características o rasgos, frecuentemente referidos como puntos de control del terreno GCP's<sup>1</sup>, tienen que estar bien definidos y ser espacialmente pequeños, pueden escogerse por ejemplo intersecciones de caminos o carreteras, pistas de aterrizaje de aeropuertos, entre otros, de modo que los coeficientes polinomiales puedan ser estimados. En la práctica, sin embargo, más que estos coeficientes sean simplemente calculados, se busca que sean evaluados usando como estimación el mínimo error cuadrático. De esta manera, cualquier punto de control que contenga un error significativo en su posición, tanto sobre el mapa como en la imagen, no tendrá una influencia excesiva sobre los coeficientes del polinomio.

## A.3. Interpolación.

Tomando la suposición de que los puntos localizados en la imagen corresponden exactamente a los centros de los pixels, entonces estos pixels son simplemente transferidos a la localización correspondiente sobre la rejilla que se construye en la imagen rectificadas, tal como se muestra en la Figura A.2.

<sup>1</sup> GCP's es el acrónimo de Ground Control Points

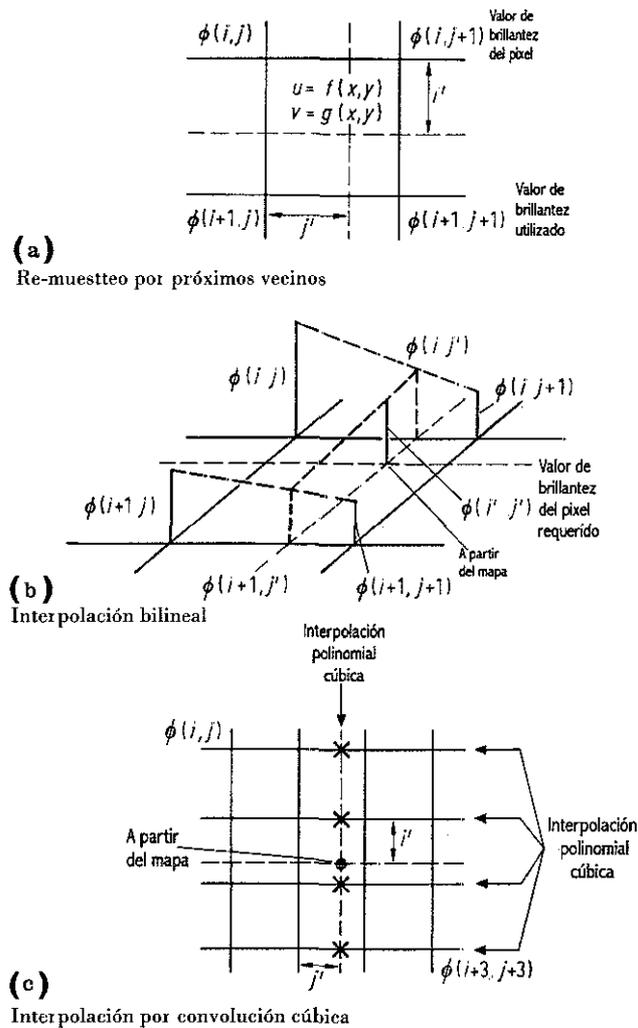


Fig. A.2. Uso del mapeo polinomial para localizar la posición de ciertos puntos de la imagen correspondiente en la rejilla desplegada.

Como es de esperarse, los centros de la rejilla de los pixels registrados en el mapa no son proyectados exactamente en el centro del pixel localizado en la imagen, como se muestra en la Figura A.2, por lo que algunas decisiones tienen que ser tomadas acerca de cual valor del pixel debe ser elegido para colocarlo sobre la nueva rejilla. Tres técnicas pueden ser utilizadas para este propósito:

- Re-muestreo por Próximos Vecinos
- Interpolación Bilineal
- Interpolación por Convolución Cúbica

Re-muestreo por Próximos Vecinos.

Simplemente se escoge el pixel actual que tenga su centro más próximo al punto localizado en la imagen, como se muestra en la Figura A.2a. Este pixel es entonces transferido a su ubicación correspondiente en la rejilla.



### Interpolación Bilineal.

Se utilizan tres interpolaciones lineales sobre cuatro pixels que circunden el punto encontrado en la imagen correspondiente a una posición dada en la rejilla. El proceso se ilustra en la Figura A.2b. Dos interpolaciones lineales son desarrolladas a lo largo de las líneas para encontrar las funciones de interpolación  $\phi(i, j')$  y  $\phi(i+1, j')$  y está dadas por

$$\phi(i, j') = j' \phi(i, j+1) + (1 - j') \phi(i, j) \quad (1.3-1)$$

$$\phi(i+1, j') = j' \phi(i+1, j+1) + (1 - j') \phi(i+1, j) \quad (1.3-2)$$

donde  $\phi$  es la brillantez del pixel e  $(i', j')$  es la posición en la cual un valor interpolado para la brillantez es requerido. La posición es medida con respecto a  $(i, j)$  y se asume un espaciamiento de la rejilla de una unidad en ambas direcciones. El paso final es la interpolación lineal sobre  $\phi(i, j')$  y  $\phi(i+1, j')$ , dada por

$$\phi(i', j') = (1 - i') \{j' \phi(i, j+1) + (1 - j') \phi(i, j)\} + i' \{j' \phi(i+1, j+1) + (1 - j') \phi(i+1, j)\} \quad (1.3-3)$$

### Interpolación por Convolución Cúbica.

Se utilizan 16 pixels que forman una vecindad de 4 x 4, polinomios de tercer orden son encontrados a lo largo de las cuatro líneas, compuestas de cuatro pixels, al punto en la imagen, como se puede apreciar en la Figura A.2c para formar cuatro funciones de interpolación. Un quinto polinomio cúbico es entonces encontrado a través de estos para obtener un valor de la brillantez para la localización correspondiente en la rejilla. Un algoritmo que es utilizado para desarrollar una interpolación por convolución cúbica es

$$\begin{aligned} \phi(i, j') = & j' \{j' (j' [\phi(i, j+3) - \phi(i, j+2) + \phi(i, j+1) - \phi(i, j)] \\ & + [\phi(i, j+2) - \phi(i, j+3) - 2\phi(i, j+1) + 2\phi(i, j)]) \\ & + [\phi(i, j+2) - \phi(i, j)]\} \\ & + \phi(i, j+1) \end{aligned} \quad (1.3-4)$$

Esta expresión es evaluada para cada una de las cuatro líneas de los cuatro pixels mostrados en la Figura A.2c, obteniéndose las cuatro funciones de interpolación  $\phi(i, j')$ ,  $\phi(i+1, j')$ ,  $\phi(i+2, j')$  y  $\phi(i+3, j')$ . Estas funciones son ahora interpoladas a la vez de manera vertical, de acuerdo a

$$\begin{aligned} \phi(i', j') = & i' \{i' [i' [\phi(i+3, j') - \phi(i+2, j') + \phi(i+1, j') - \phi(i, j')] \\ & + [\phi(i+2, j') - \phi(i+3, j') - 2\phi(i+1, j') + 2\phi(i, j')]] \\ & + [\phi(i+2, j') - \phi(i, j')]\} \\ & + \phi(i+1, j') \end{aligned} \quad (1.3-5)$$

#### A.4. Escogiendo puntos de control.

Suficientes pares de puntos de control deben ser seleccionados en la rectificación de una imagen para asegurarse que un mapeo polinomial correcto sea generado. Sin embargo, también se debe tener cuidado al dar la localización de los puntos. Una regla general es que se debe de tener una distribución de los puntos de control en el terreno, por lo que se pueden distribuir de manera uniforme para lograr una dispersión de puntos sobre toda la imagen, tratando de que ésta sea de manera uniforme para asegurar que el mapeo se realizará de manera satisfactoria sobre la imagen (Richards y Jia, 1986).

#### A.5. Corrección de la Distorsión Geométrica.

Para el caso en particular del presente trabajo de tesis se utilizó la imagen de radar Seasat de una zona del Norte de México, la cual abarca parte de los estados de Coahuila, Chihuahua y Nuevo León. La imagen obtenida directamente del radar se muestra en la Figura A.3.



Figura A.3. Imagen Seasat original degradada por ruido.

Para realizar la georeferenciación se tomaron en cuenta como mapa las cartas topográficas que se indican en la Tabla A.1, a una escala de 1:250 000, obtenidas del Instituto Nacional de Estadística, Geografía e Informática, INEGI.

Tabla A.1. Cartas topográficas que abarcan la zona de la imagen Seasat.

CARTAS TOPOGRÁFICAS		
LOCALIZACIÓN	ZONA	REGIÓN
G14 - 1	Nueva Rosita	Coahuila y Nuevo León
G14 - 4	Monclova	Coahuila y Nuevo León
G13 - 3	Ocampo	Coahuila y Chihuahua

El índice de localización mostrado en la primera columna de la Tabla A.1 está dado de acuerdo al INEGI, como se muestra en el mapa de la Figura A.4.

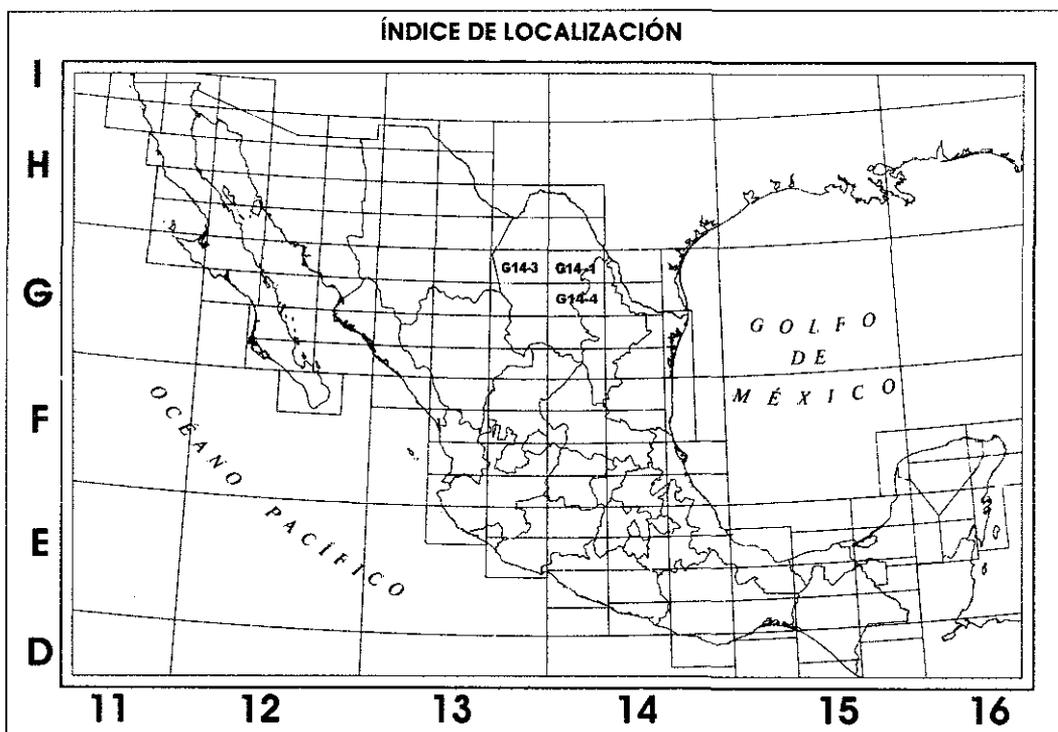


Figura A.4. Mapa del índice de localización de las cartas topográficas elaboradas por el INEGI.

La paquetería computacional que se utilizó para llevar a cabo la georeferenciación de la imagen original fue ENVI<sup>2</sup>, Versión 3.2. Se procedió a introducir seis puntos de control distribuidos en toda la imagen, donde la mayor parte de estos se localizaron en la carta topográfica de la zona de Nueva Rosita, ya que es en esta carta donde se encuentra la mayor parte de la imagen. Los puntos de

<sup>2</sup> ENVI es el acrónimo de "The Environment for Visualizing Images."

control que se utilizaron son los que se muestran en la Tabla A.2, se dieron dichos puntos con base en los siguientes datos que fueron proporcionados al sistema:

Proyección de Registro: Geográfica Lat/Lon  
 Datos: Norte América, 1927  
 Unidades: Grados  
 Tamaño del pixel X: 25.00 m  
 Tamaño del pixel Y: 25.00 m

Tabla A.2. Puntos de Control localizados en la imagen (coordenadas pixel) y en el mapa de la zona (coordenadas geográficas).

PUNTOS DE CONTROL				
Coordenadas Pixel (x,y)		Coordenadas Geográficas (Lat - Lon)		ZONA
4333	2708	27° 28' 12"	-101° 39' 00"	Nueva Rosita
1956	3191	27° 09' 36"	-101° 27' 00"	Nueva Rosita
5610	3355	27° 41' 24"	-101° 37' 12"	Nueva Rosita
1675	1485	27° 02' 24"	-101° 41' 24"	Nueva Rosita
783	392	26° 51' 00"	-101° 48' 36"	Monclova
5752	820	27° 34' 48"	-102° 01' 12"	Ocampo

Una vez introducidos los puntos de control se llevó a cabo la georreferenciación utilizando un mapeo polinomial de primer orden, es decir, lineal y a la vez utilizando una interpolación bilineal, donde el error medio cuadrático o RMS que se obtuvo después de minimizarlo fue de 0.9184 pixeles. La imagen georreferenciada se muestra en la Figura A.5, donde las coordenadas de las esquinas que encierran a la zona de interés de la imagen se muestran en la Tabla A.3.

Tabla A.3. Coordenadas geográficas de las esquinas de la imagen georreferenciada.

IMAGEN GEORREFERENCIADA		
	Coordenadas Geográficas (Lat - Lon)	
A	27° 34' 56.71" N	-102° 09' 50.29" W
B	27° 50' 39.79" N	-101° 22' 09.34" W
C	26° 59' 13.77" N	-101° 02' 59.42" W
D	26° 43' 21.46" N	-101° 49' 41.28" W



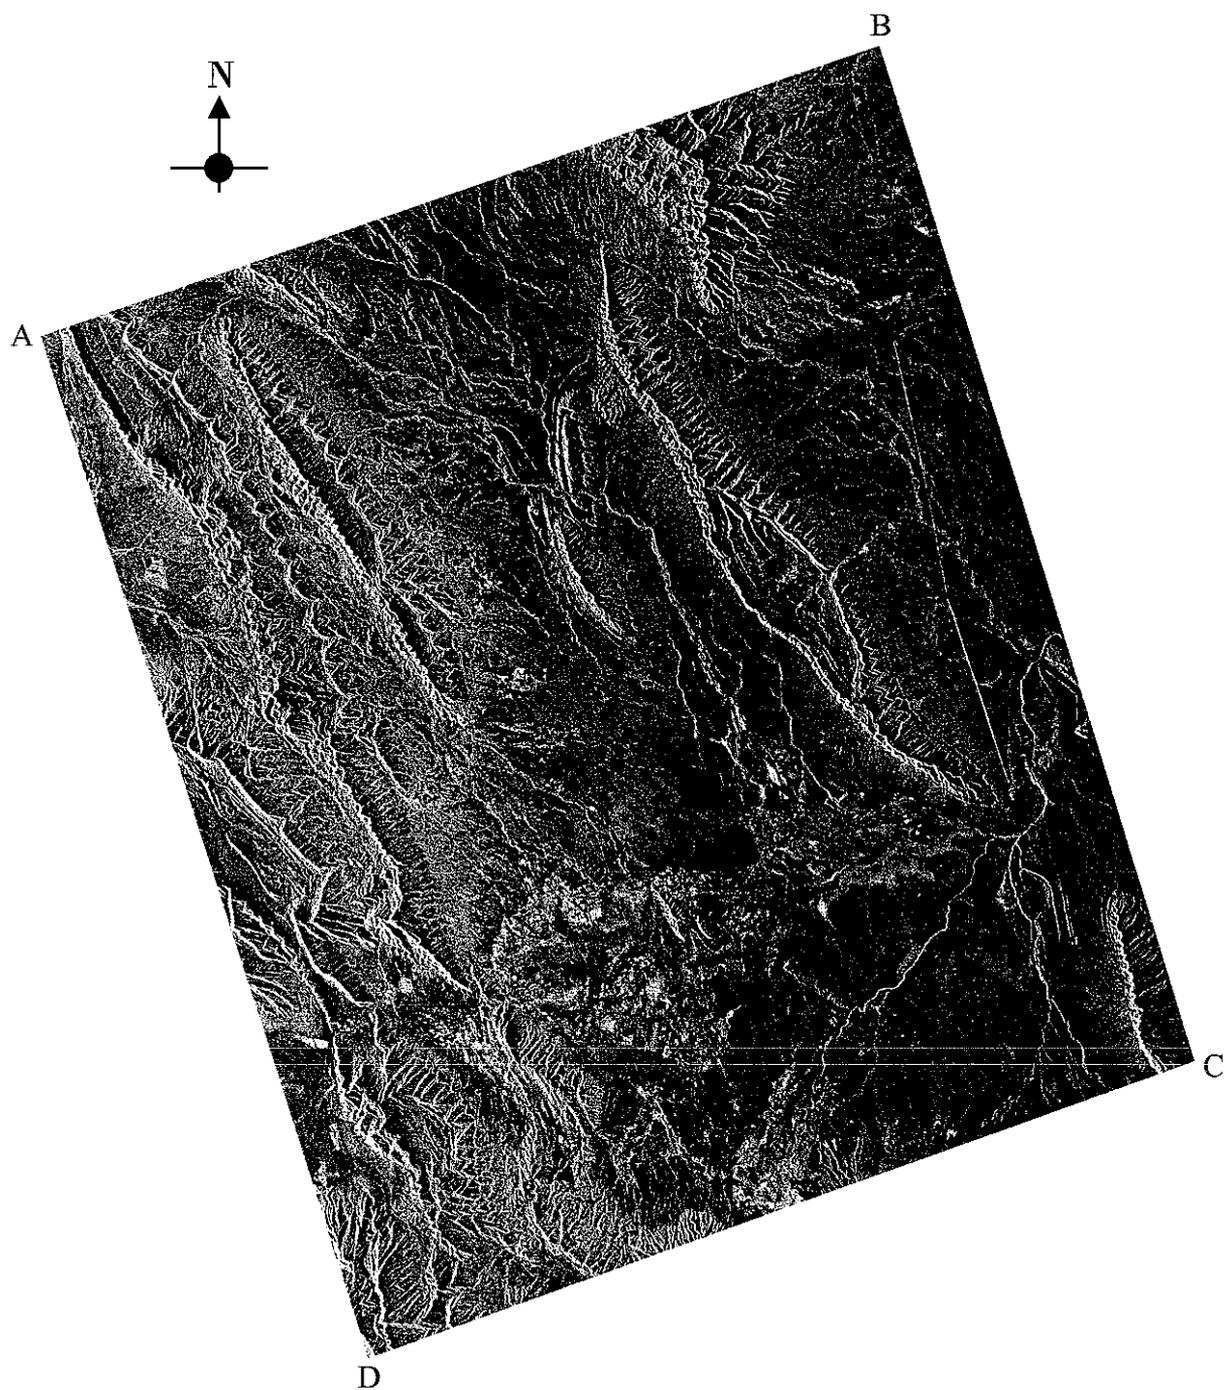


Figura A.5. Imagen Seasat georeferenciada.

TESIS CON  
FALLA DE ORIGEN

## **ANEXO B.**

### **RESULTADOS OBTENIDOS DE LOS CRITERIOS DE EVALUACIÓN DE LA CALIDAD DE UNA IMAGEN.**

A continuación se presenta tanto la imagen original degradada por ruido, como las imágenes filtradas resultantes obtenidas con cada uno de los filtros mencionados en el capítulo 3. En la Figura B.1 se muestra la imagen original degradada por ruido y en las Figuras B.2 – B.7 se muestran las imágenes que se obtuvieron al aplicarles un filtrado de acuerdo a los algoritmos de Filtro Geométrico para una y dos iteraciones, Lee Multiplicativo, Frost Kuan y Sigma, respectivamente. Como puede observarse a simple vista se tienen imágenes con resultados diferentes, en algunas, la definición de bordes se llega a perder en cierta forma, mientras que en otros se pueden ver aunque no con la misma claridad en todas las imágenes, pero para hacer un análisis más específico de los resultados obtenidos acerca de la calidad que se tiene en cada imagen se han calculado los factores y criterios para la evaluación de una imagen descritos con anterioridad, utilizando el programa desarrollado en el laboratorio de Percepción Remota del Instituto de Geofísica, UNAM.



Fig. B.1. Imagen Seasat original degradada por ruido (speckle).

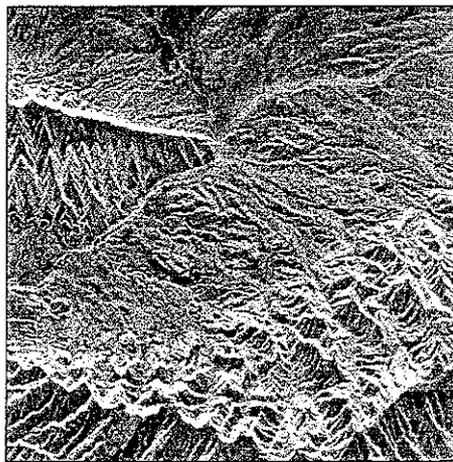


Fig. B.2. Imagen Seasat filtrada, utilizando el filtro geométrico (SANDI) con una iteración.

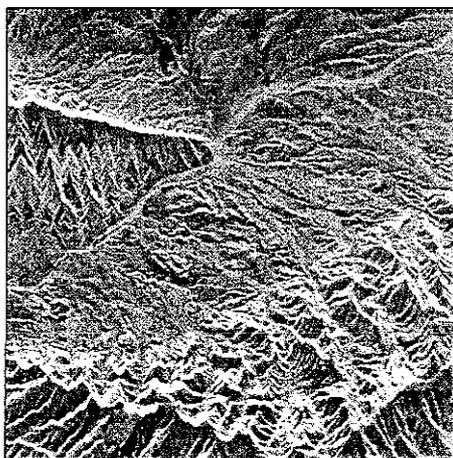


Fig. B.3. Imagen Seasat filtrada, utilizando filtro geométrico (SANDI) con dos iteraciones.



Fig. B.4. Imagen Seasat filtrada, utilizando filtro de Lee-Multiplicativo (ENVI).



Fig. B.5. Imagen Seasat filtrada, utilizando el filtro de Frost (ENVI).

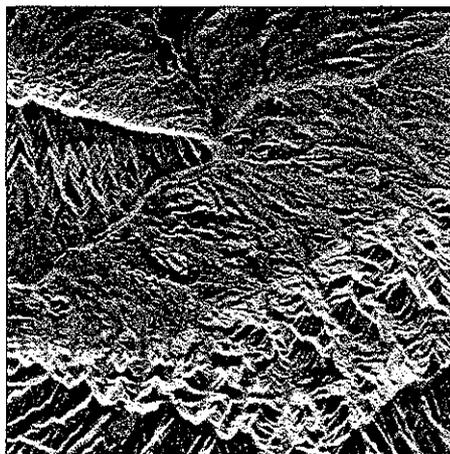


Fig. B.6. Imagen Seasat filtrada, utilizando el filtro de Kuan (ENVI).

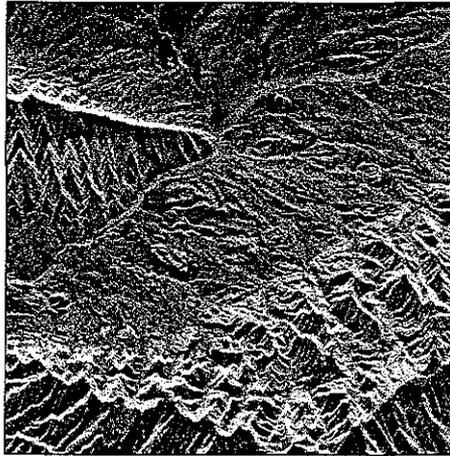


Fig. B.7. Imagen Seasat filtrada, utilizando el filtro Sigma (ENVI).

TESIS CON  
FALLA DE ORIGEN

**FACTORES GLOBALES:**

Factor de Contraste (1) .....  $fc_1$   
 Factor de Contraste (2) .....  $fc_2$   
 Factor de Contraste (3) .....  $fc_3$   
 Media .....  $\mu$   
 Desviación Estándar .....  $\sigma$   
 Dispersión ..... D

Tabla B.1. Factores Globales para evaluación de la calidad de la imagen SEASAT (998x998).

Factor Global	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
$fc_1$	34.1438	5.4501	2.7977	42.0149	29.9394	42.6317	55.0996
$fc_2$	115.6606	29.4268	18.2881	143.1142	98.3597	133.0087	164.1796
$fc_3$	142.4541	7.2018	24.8166	127.4414	105.8253	127.7935	142.8649
$\mu$	137.1016	145.1015	145.5015	106.4517	101.7544	103.7729	106.4362
$\sigma$	57.2216	43.5421	40.7499	64.5381	60.2483	62.4091	67.0565
D	7.5645	6.5986	6.3836	8.0336	7.7620	7.8999	8.1888

TESIS CON  
FALLA DE ORIGEN



Tabla B.3. Factores Locales para evaluación de la calidad de la imagen SEASAT filtrada con Filtro Geométrico (1 iteración).

Imagen Filtrada (Filtro Geométrico – 1 iteración)						
Ventana	$\mu$	$\sigma$	$\beta$	snr	$\epsilon_1$	$\epsilon_2$
1	74.0000	7.1308	0.0964	10.3776	12.2990	91.2108
2	68.3320	8.2024	0.1200	8.3307	10.8667	89.2827
3	88.1992	15.4158	0.1748	5.7213	6.0917	85.1220
4	94.6055	8.3578	0.0883	11.3194	10.6863	91.8827
5	96.7227	18.0868	0.1870	5.3477	5.2392	84.2462
6	92.1827	16.7345	0.1815	5.5086	5.6387	84.6356
7	73.8281	9.1268	0.1236	8.0892	9.8748	88.9979
8	84.3633	12.8456	0.1523	6.5675	7.2225	86.7856
9	74.4063	8.2897	0.1114	8.9757	10.7646	89.9757
10	71.9766	7.2440	0.1006	9.9360	12.1300	90.8559
11	81.4531	7.5972	0.0933	10.7215	11.6318	91.4687
12	79.9063	8.0755	0.1011	9.8949	11.0187	90.8214
13	89.3555	12.6594	0.1417	7.0584	7.3210	87.5906
14	95.9492	21.7775	0.2270	4.4059	4.3903	81.5016
15	82.2461	10.9309	0.1329	7.5242	8.3816	88.2687

Tabla B.4. Factores Locales para evaluación de la calidad de la imagen SEASAT filtrada con Filtro Geométrico (2 iteraciones).

Imagen Filtrada (Filtro Geométrico – 2 iteraciones)						
Ventana	$\mu$	$\sigma$	$\beta$	snr	$\epsilon_1$	$\epsilon_2$
1	75.0352	3.8557	0.0514	19.4609	20.5944	95.1126
2	68.5820	5.3925	0.0786	12.7181	15.6434	92.7104
3	89.8438	13.5124	0.1504	6.6490	6.8907	86.9264
4	95.1602	6.5368	0.0687	14.5576	13.2682	93.5723
5	97.1563	14.8959	0.1533	6.5224	6.2909	86.7063
6	91.6683	13.8802	0.1514	6.6042	6.7203	86.8494
7	74.4844	7.6115	0.1022	9.7857	11.6123	90.7285
8	84.9141	9.0755	0.1069	9.3564	9.9251	90.3441
9	73.3125	5.7556	0.0785	12.7375	14.8025	92.7207
10	73.6289	4.3208	0.0587	17.0405	18.7941	94.4569
11	82.5703	4.2731	0.0518	19.3234	18.9643	95.0796
12	80.9883	5.8801	0.0726	13.7734	14.5348	93.2311
13	90.4805	10.1354	0.1120	8.09271	8.9803	89.9266
14	97.6367	19.0518	0.1951	5.1248	4.9871	83.6729
15	83.6992	9.0706	0.1084	9.2275	9.9299	90.2224

Tabla B.5. Factores Locales para evaluación de la calidad de la imagen SEASAT filtrada con Filtro de Lee Multiplicativo.

Imagen Filtrada (Filtro de Lee Multiplicativo)						
Ventana	$\mu$	$\sigma$	$\beta$	snr	$\varepsilon_1$	$\varepsilon_2$
1	17.7852	21.8282	1.2273	0.8148	4.3806	44.8969
2	12.6484	16.7762	1.3263	0.7539	5.6255	42.9858
3	31.5898	30.6899	0.9715	1.0293	3.1556	50.7225
4	40.1992	30.0034	0.7464	1.3398	3.2255	57.2617
5	46.5469	36.0511	0.7745	1.2911	2.6990	56.3535
6	40.1010	36.2432	0.9038	1.1064	2.6851	52.5265
7	18.9414	18.4436	0.9737	1.0270	5.1431	50.6658
8	29.6367	30.4691	1.0281	0.9727	3.1777	49.3076
9	25.6875	15.2326	0.5930	1.6863	6.1604	62.7748
10	13.7656	18.9118	1.3738	0.7279	5.0221	42.1258
11	26.1406	22.1369	0.8468	1.1809	4.3221	54.1465
12	23.0117	22.1125	0.9609	1.0407	4.3267	50.9964
13	36.7148	26.5597	0.7234	1.3824	3.6285	58.0247
14	42.4180	37.3840	0.8813	1.1347	2.6053	53.1540
15	27.4609	21.8354	0.7951	1.2576	4.3792	55.7059

Tabla B.6. Factores Locales para evaluación de la calidad de la imagen SEASAT filtrada con Filtro de Frost.

Imagen Filtrada (Filtro de Frost)						
Ventana	$\mu$	$\sigma$	$\beta$	snr	$\varepsilon_1$	$\varepsilon_2$
1	8.7734	10.2202	1.1649	0.8584	8.9125	46.1914
2	1.0430	2.4264	2.3265	0.4298	29.1848	30.0619
3	15.0859	18.0780	1.1983	0.8345	5.2417	45.4890
4	27.9297	18.2182	0.6523	1.5331	5.2034	60.5221
5	26.6133	24.5805	0.9236	1.0827	3.9092	51.9854
6	4.9952	10.7012	2.1423	0.4668	8.5461	31.8238
7	13.5508	11.7710	0.8687	1.1512	7.8303	53.5144
8	19.6953	21.1135	1.0720	0.9328	4.5221	48.2624
9	0.0000	0.0000	0.0000	$\infty$	100.0000	100.0000
10	3.6094	7.6838	2.1288	0.4697	11.5157	31.9607
11	18.2617	12.7456	0.6979	1.4328	7.2750	58.8948
12	13.1016	12.5120	0.9550	1.0471	7.4009	51.1510
13	40.3867	25.1144	0.6218	1.6081	3.8293	61.6580
14	42.4141	31.3237	0.7385	1.3541	3.0937	57.5202
15	27.7500	19.4710	0.7017	1.4252	4.8850	58.7662

TESIS CON  
FALLA DE ORIGEN

Tabla B.7. Factores Locales para evaluación de la calidad de la imagen SEASAT filtrada con Filtro de Kuan.

Imagen Filtrada (Filtro de Kuan)						
Ventana	$\mu$	$\sigma$	$\beta$	snr	$\epsilon_1$	$\epsilon_2$
1	8.9883	13.4642	1.4980	0.6676	6.9136	40.0325
2	4.1758	8.2042	1.9647	0.5090	10.8646	33.7302
3	23.0664	26.7120	1.1580	0.8635	3.6085	46.3381
4	30.0156	24.1344	0.8041	1.2437	3.9786	55.4305
5	36.2072	30.6166	0.8456	1.1826	3.1629	54.1829
6	29.5962	29.8769	1.0095	0.9906	3.2387	49.7640
7	12.5859	12.1679	0.9668	1.0344	7.5942	50.8444
8	19.2813	22.6259	1.1735	0.8522	4.2326	46.0095
9	15.2813	9.6591	0.6321	1.5821	9.3816	61.2712
10	5.6563	11.2588	1.9905	0.5024	8.1574	33.4391
11	17.0625	15.0645	0.8829	1.1326	6.2249	53.1095
12	13.2031	15.0347	1.1387	0.8782	6.2365	46.7569
13	29.6719	20.5622	0.6930	1.4430	4.6378	59.0673
14	36.3555	32.7063	0.8996	1.1116	2.9668	52.6419
15	20.8438	16.4605	0.7897	1.2663	5.7272	55.8750

Tabla B.8. Factores Locales para evaluación de la calidad de la imagen SEASAT filtrada con Filtro Sigma Local.

Imagen Filtrada (Filtro Sigma Local)						
Ventana	$\mu$	$\sigma$	$\beta$	snr	$\epsilon_1$	$\epsilon_2$
1	19.8789	26.5699	1.3366	0.7482	3.6271	42.7975
2	13.8750	18.9889	1.3686	0.7307	5.0028	42.2196
3	32.9570	35.0111	1.0623	0.9423	2.7769	48.4890
4	41.4805	35.1140	0.8465	1.1813	2.7690	54.1560
5	46.5273	40.6881	0.8745	1.1435	2.3988	53.3476
6	41.6827	34.8343	0.8357	1.1966	2.7906	54.4751
7	20.6523	22.0006	1.0653	0.9387	4.3477	48.4195
8	29.4141	34.2040	1.1628	0.8600	2.8406	46.2354
9	18.9844	1.4615	0.0770	12.9899	40.6261	92.8520
10	15.6484	22.9346	1.4656	0.6823	4.1781	40.5578
11	27.5117	26.5056	0.9634	1.0380	3.6356	50.9313
12	24.1953	26.5100	1.0957	0.9127	3.6350	47.7175
13	37.5234	31.0401	0.8272	1.2089	3.1211	54.7280
14	41.7969	39.4347	0.9435	1.0599	2.4731	51.4540
15	29.2227	26.0201	0.8904	1.1231	3.7010	52.8986



Tabla B.9. Factores de Evaluación en zonas homogéneas: Medias Locales.

Ventana	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
1	69.2344	74.0000	75.0352	17.7852	8.7734	8.9883	19.8789
2	65.4102	68.3320	68.5820	12.6484	1.0430	4.1758	13.8750
3	81.7461	88.1992	89.8438	31.5898	15.0859	23.0664	32.9570
4	88.5703	94.6055	95.1602	40.1992	27.9297	30.0156	41.4805
5	92.5547	96.7227	97.1563	46.5469	26.6133	36.2072	46.5273
6	88.0817	92.1827	91.6683	40.1010	4.9952	29.5962	41.6827
7	69.7695	73.8281	74.4844	18.9414	13.5508	12.5859	20.6523
8	79.3555	84.3633	84.9141	29.6367	19.6953	19.2813	29.4141
9	74.9688	74.4063	73.3125	25.6875	0.0000	15.2813	18.9844
10	66.2891	71.9766	73.6289	13.7656	3.6094	5.6563	15.6484
11	76.4805	81.4531	82.5703	26.1406	18.2617	17.0625	27.5117
12	73.9023	79.9063	80.9883	23.0117	13.1016	13.2031	24.1953
13	83.4102	89.3555	90.4805	36.7148	40.3867	29.6719	37.5234
14	88.2266	95.9492	97.6367	42.4180	42.4141	36.3555	41.7969
15	76.6016	82.2461	83.6992	27.4609	27.7500	20.8438	29.2227

Tabla B.10. Factor de Evaluación en zonas homogéneas: Desviaciones Estándar Locales.

Ventana	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
1	27.7459	7.1308	3.8557	21.8282	10.2202	13.4642	26.5699
2	23.3072	8.2024	5.3925	16.7762	2.4264	8.2042	18.9889
3	32.8970	15.4158	13.5124	30.6899	18.0780	26.7120	35.0111
4	33.6783	8.3578	6.5368	30.0034	18.2182	24.1344	35.1140
5	38.0053	18.0868	14.8959	36.0511	24.5805	30.6166	40.6881
6	38.0261	16.7345	13.8802	36.2432	10.7012	29.8769	34.8343
7	24.1855	9.1268	7.6115	18.4436	11.7710	12.1679	22.0006
8	32.7751	12.8456	9.0755	30.4691	21.1135	22.6259	34.2040
9	22.5748	8.2897	5.7556	15.2326	0.0000	9.6591	1.4615
10	24.6210	7.2440	4.3208	18.9118	7.6838	11.2588	22.9346
11	27.5375	7.5972	4.2731	22.1369	12.7456	15.0645	26.5056
12	27.4444	8.0755	5.8801	22.1125	12.5120	15.0347	26.5100
13	31.5510	12.6594	10.1354	26.5597	25.1144	20.5622	31.0401
14	37.6780	21.7775	19.0518	37.3840	31.3237	32.7063	39.4347
15	27.2931	10.9309	9.0706	21.8354	19.4710	16.4605	26.0201

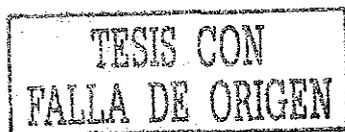


Tabla B.11. Factor de Evaluación en zonas homogéneas: Contenido de Ruido (índice Speckle).

Ventana	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
1	0.4008	0.0964	0.0514	1.2273	1.1649	1.4980	1.3366
2	0.3563	0.1200	0.0786	1.3263	2.3265	1.9647	1.3686
3	0.4024	0.1748	0.1504	0.9715	1.1983	1.1580	1.0623
4	0.3802	0.0883	0.0687	0.7464	0.6523	0.8041	0.8465
5	0.4106	0.1870	0.1533	0.7745	0.9236	0.8456	0.8745
6	0.4317	0.1815	0.1514	0.9038	2.1423	1.0095	0.8357
7	0.3466	0.1236	0.1022	0.9737	0.8687	0.9668	1.0653
8	0.4130	0.1523	0.1069	1.0281	1.0720	1.1735	1.1628
9	0.3011	0.1114	0.0785	0.5930	0.0000	0.6321	0.0770
10	0.3714	0.1006	0.0587	1.3738	2.1288	1.9905	1.4656
11	0.3601	0.0933	0.0518	0.8468	0.6979	0.8829	0.9634
12	0.3714	0.1011	0.0726	0.9609	0.9550	1.1387	1.0957
13	0.3783	0.1417	0.1120	0.7234	0.6218	0.6930	0.8272
14	0.4271	0.2270	0.1951	0.8813	0.7385	0.8996	0.9435
15	0.3563	0.1329	0.1084	0.7951	0.7017	0.7897	0.8904

Tabla B.12. Factor de Evaluación en zonas homogéneas: Relación Señal - Ruido (snr).

Ventana	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
1	2.4953	10.3776	19.4609	0.8148	0.8584	0.6676	0.7482
2	2.8064	8.3307	12.7181	0.7539	0.4298	0.5090	0.7307
3	2.4849	5.7213	6.6490	1.0293	0.8345	0.8635	0.9423
4	2.6299	11.3194	14.5576	1.3398	1.5331	1.2437	1.1813
5	2.4353	5.3477	6.5224	1.2911	1.0827	1.1826	1.1435
6	2.3163	5.5086	6.6042	1.1064	0.4668	0.9906	1.1966
7	2.8848	8.0892	9.7857	1.0270	1.1512	1.0344	0.9387
8	2.4212	6.5675	9.3564	0.9727	0.9328	0.8522	0.8600
9	3.3209	8.9757	12.7375	1.6863	∞	1.5821	12.9899
10	2.6924	9.9360	17.0405	0.7279	0.4697	0.5024	0.6823
11	2.7773	10.7215	19.3234	1.1809	1.4328	1.1326	1.0380
12	2.6928	9.8949	13.7734	1.0407	1.0471	0.8782	0.9127
13	2.6437	7.0584	809271	1.3824	1.6081	1.4430	1.2089
14	2.3416	4.4059	5.1248	1.1347	1.3541	1.1116	1.0599
15	2.8066	7.5242	9.2275	1.2576	1.4252	1.2663	1.1231

Tabla B.13. Factor de Evaluación en zonas homogéneas: Porcentaje de Homogeneidad ( $\epsilon_1$ ).

Ventana	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
1	3.4788	12.2990	20.5944	4.3806	8.9125	6.9136	3.6271
2	4.1140	10.8667	15.6434	5.6255	29.1848	10.8646	5.0028
3	2.9501	6.0917	6.8907	3.1556	5.2417	3.6085	2.7769
4	2.8836	10.6863	13.2682	3.2255	5.2034	3.9786	2.7690
5	2.5638	5.2392	6.2909	2.6990	3.9092	3.1629	2.3988
6	2.5624	5.6387	6.7203	2.6851	8.5461	3.2387	2.7906
7	3.9705	9.8748	11.6123	5.1431	7.8303	7.5942	4.3477
8	2.9608	7.2225	9.9251	3.1777	4.5221	4.2326	2.8406
9	4.2418	10.7646	14.8025	6.1604	100.0000	9.3816	40.6261
10	3.9031	12.1300	18.7941	5.0221	11.5157	8.1574	4.1781
11	3.5042	11.6318	18.9643	4.3221	7.2750	6.2249	3.6356
12	3.5156	11.0187	14.5348	4.3267	7.4009	6.2365	3.6350
13	3.0721	7.3210	8.9803	3.6285	3.8293	4.6378	3.1211
14	2.5855	4.3903	4.9871	2.6053	3.0937	2.9668	2.4731
15	3.5344	8.3816	9.9299	4.3792	4.8850	5.7272	3.7010

Tabla B.14. Factor de Evaluación en zonas homogéneas: Porcentaje de Homogeneidad ( $\epsilon_2$ ).

Ventana	Imagen Original Degradada por ruido	Imágenes filtradas					
		Filtro Geométrico (1 iteración)	Filtro Geométrico (2 iteraciones)	Filtro de Lee	Filtro de Frost	Filtro de Kuan	Filtro Sigma
1	71.3902	91.2108	95.1126	44.8969	46.1914	40.0325	42.7975
2	73.7287	89.2827	92.7104	42.9858	30.0619	33.7302	42.2196
3	71.3049	85.1220	86.9264	50.7225	45.4890	46.3381	48.4890
4	72.4510	91.8827	93.5723	57.2617	60.5221	55.4305	54.1560
5	70.8906	84.2462	86.7063	56.3535	51.9854	54.1829	53.3476
6	69.8463	84.6356	86.8494	52.5265	31.8238	49.7640	54.4751
7	74.2585	88.9979	90.7285	50.6658	53.5144	50.8444	48.4195
8	70.7706	86.7856	90.3441	49.3076	48.2624	46.0095	46.2354
9	76.8567	89.9757	92.7207	62.7748	100.0000	61.2712	92.8520
10	72.9172	90.8559	94.4569	42.1258	31.9607	33.4391	40.5578
11	73.5262	91.4687	95.0796	54.1465	58.8948	53.1095	50.9313
12	72.9203	90.8214	93.2311	50.9964	51.1510	46.7569	47.7175
13	72.5551	87.5906	89.9266	58.0247	61.6580	59.0673	54.7280
14	70.0742	81.5016	83.6729	53.1540	57.5202	52.6419	51.4540
15	73.7301	88.2687	90.2224	55.7059	58.7662	55.8750	52.8986

TESIS CON FALLA DE ORIGEN

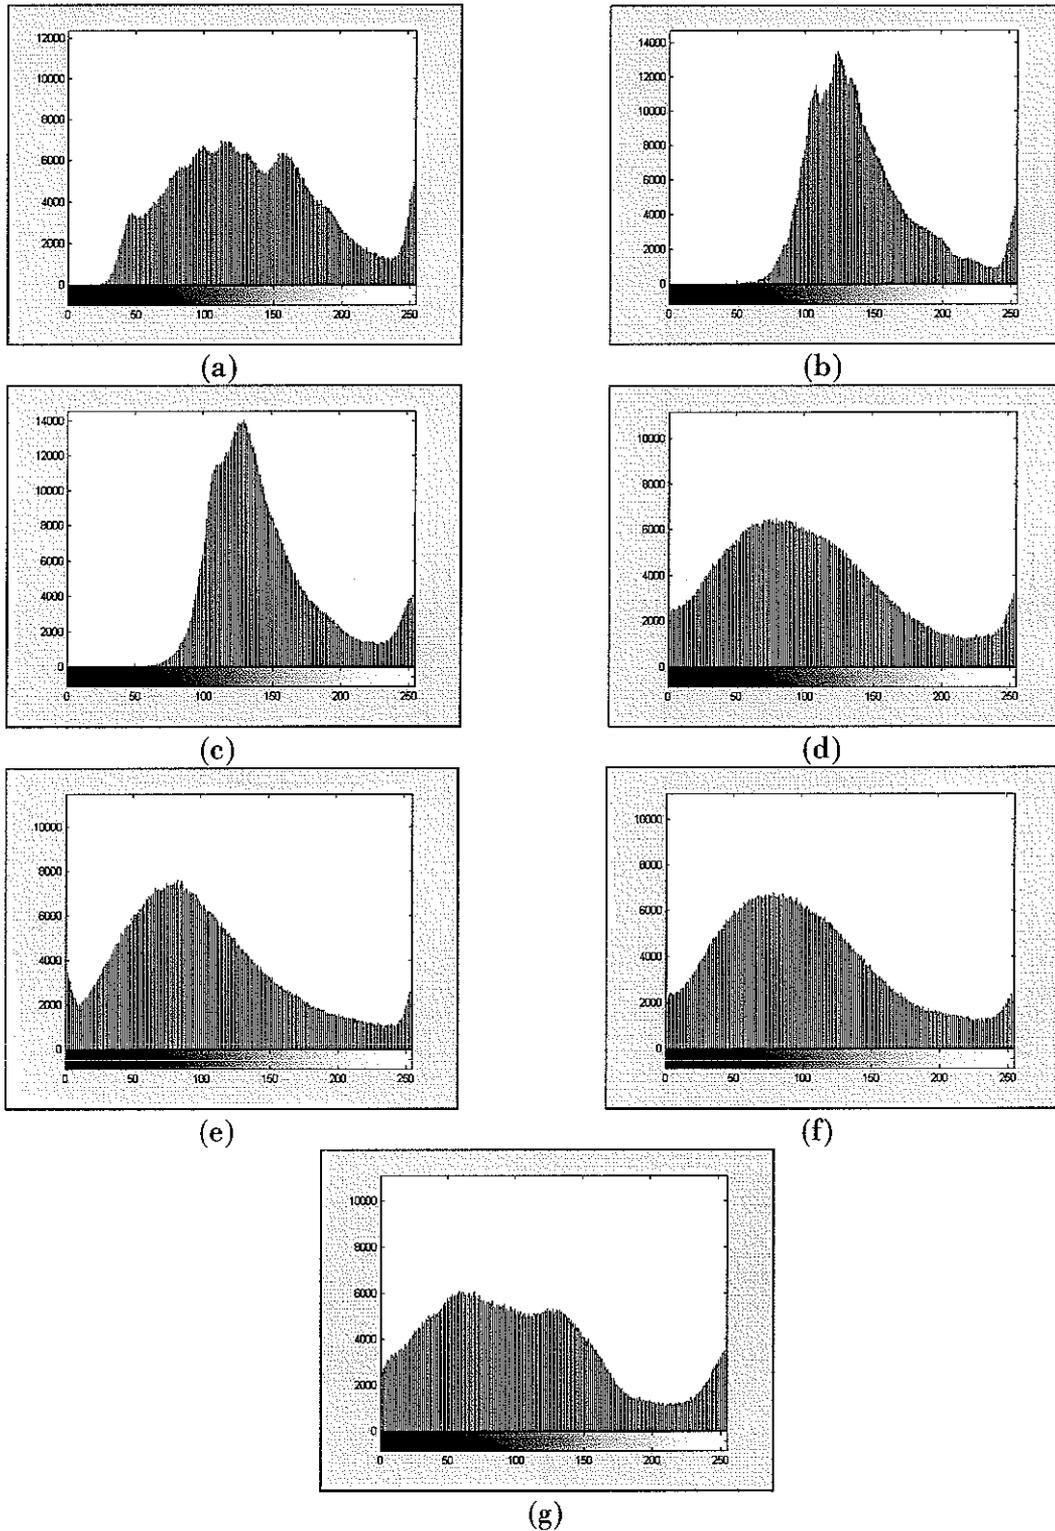


Fig. B.8 Histogramas de la imagen Seasat: a) imagen original, b) primera iteración con el filtro geométrico, c) segunda iteración con el filtro geométrico, d) filtro de Lee-Multiplicativo, e) filtro de Frost, f) filtro de Kuan y g) filtro Sigma.

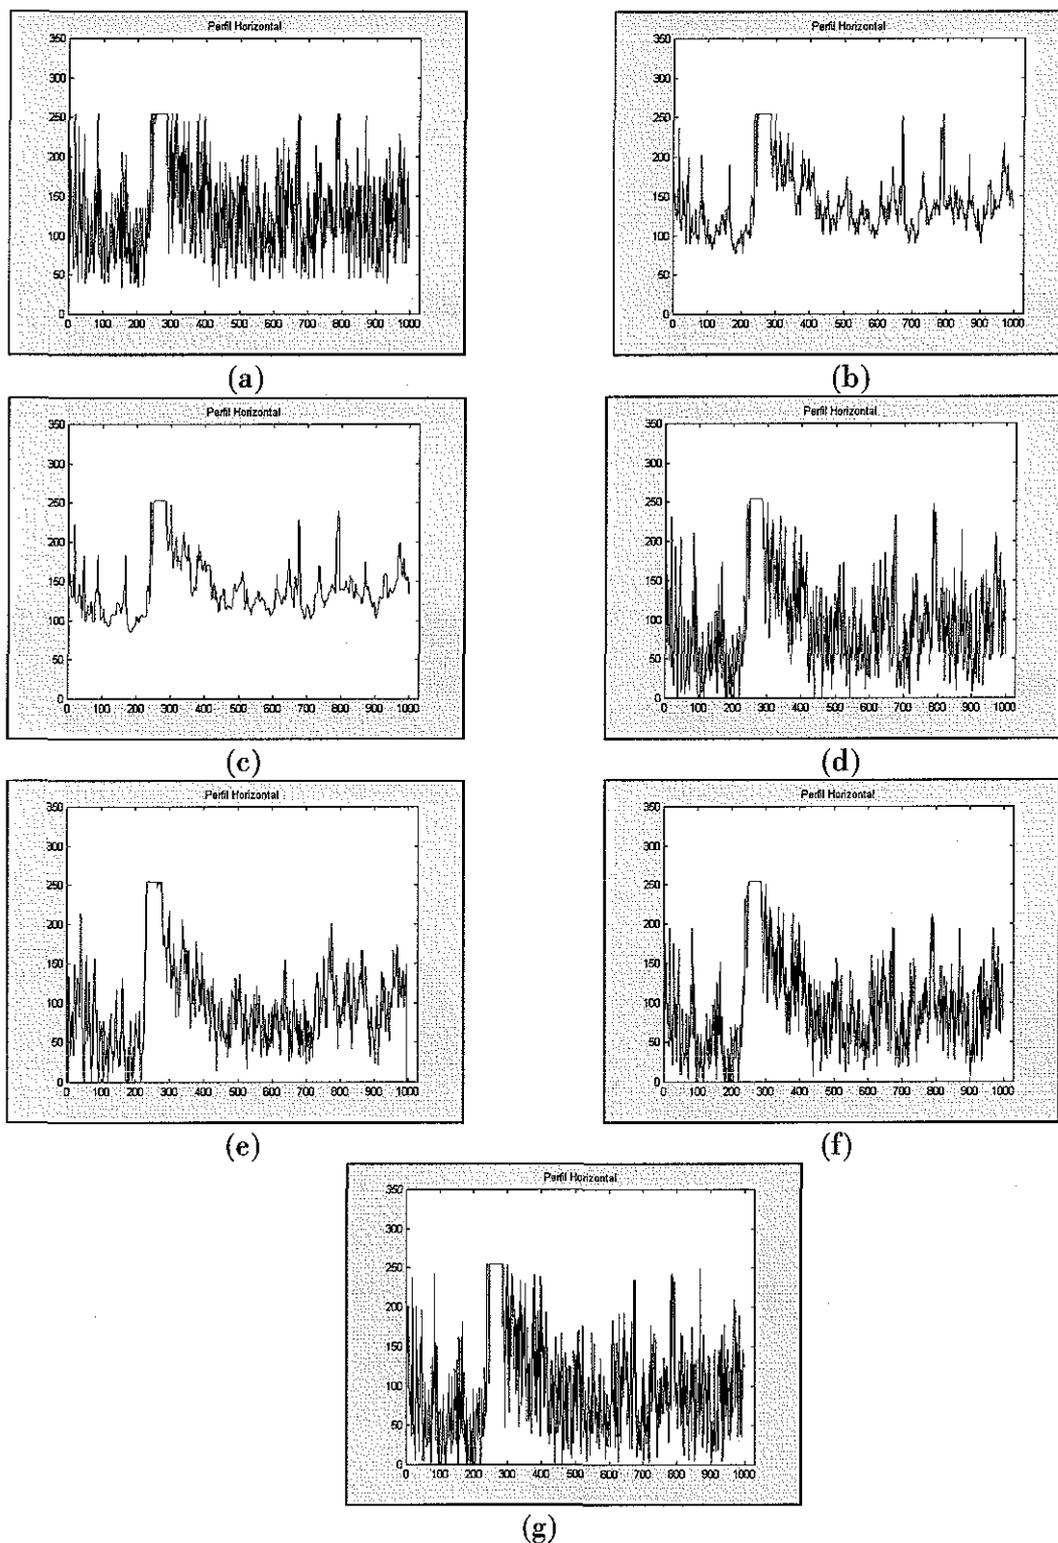


Fig. B.9 Perfiles del renglón 260 de la imagen Seasat: a) imagen original, b) primera iteración con el filtro geométrico, c) segunda iteración con el filtro geométrico, d) filtro de Lee-Multiplicativo, e) filtro de Frost, f) filtro de Kuan y g) filtro Sigma.

TESIS CON  
FALLA DE ORIGEN

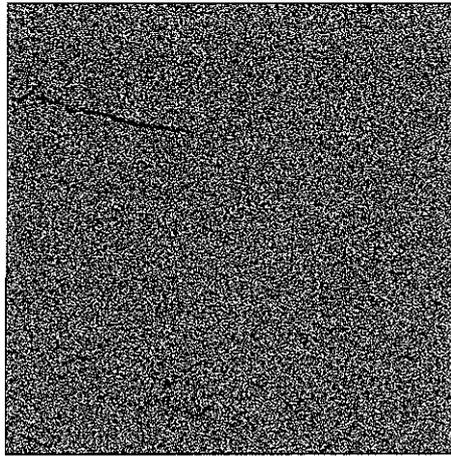


Fig. B.10. Detección de Bordes, imagen Seasat original con speckle.

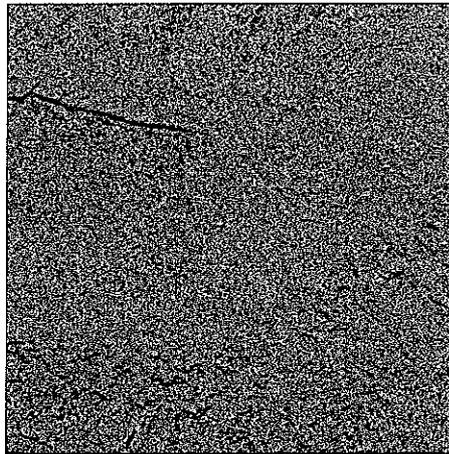


Fig. B.11. Detección de Bordes, imagen Seasat procesada con filtro geométrico: 1 iteración.

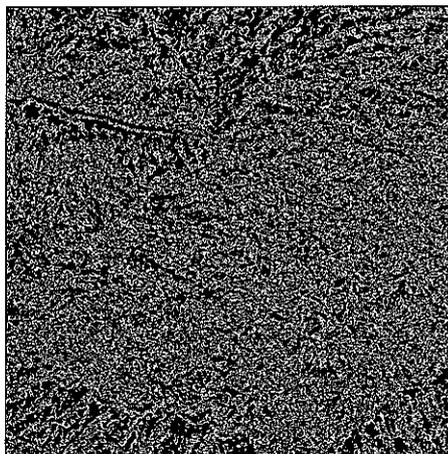


Fig. B.12. Detección de Bordes, imagen Seasat procesada con filtro geométrico: 2 iteraciones.

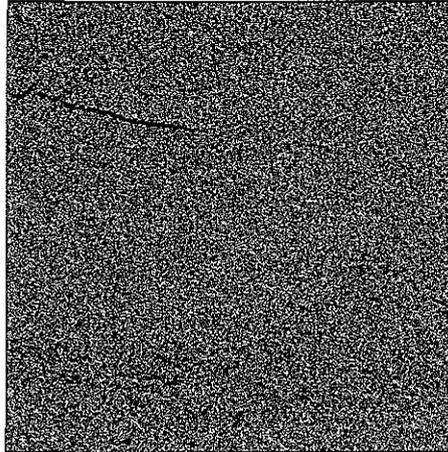


Fig. B.13. Detección de Bordes, imagen Seasat procesada con filtro de Lee-Multiplicativo.

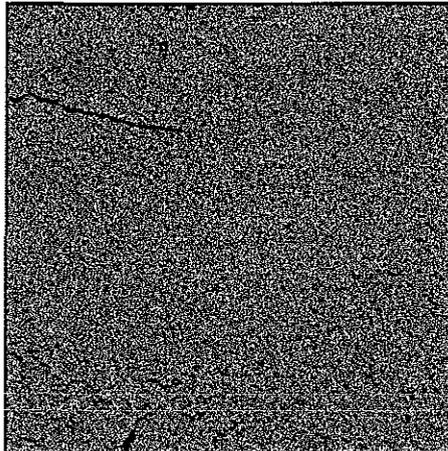


Fig. B.14. Detección de Bordes, imagen Seasat original procesada con filtro de Frost.

TESIS CON  
FALLA DE ORIGEN

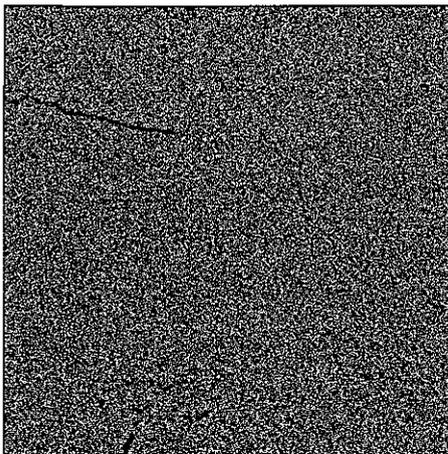


Fig. B.15. Detección de Bordes, imagen Seasat procesada con filtro de Kuan.

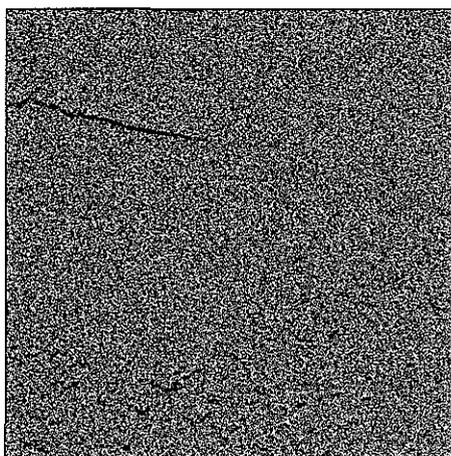


Fig. B.16. Detección de Bordes, imagen Seasat procesada con el filtro Sigma.

