

UNIVERSIDAD NACIONAL DE CÓRDOBA

FACULTAD DE MATEMÁTICA, ASTRONOMÍA Y FÍSICA
FACULTAD DE CIENCIAS EXACTAS, FÍSICAS Y NATURALES



Tesis para obtener el título de

Magister en Análisis y Procesamiento de Imágenes

MÉTODOS DE SEGMENTACIÓN DE IMÁGENES DE TEXTURA.
OPTIMIZACIÓN DEL MÉTODO OTSU.

Autora: Lic. Mónica Patricia Puente

Directora: Dra. Silvia María Ojeda

Córdoba, Argentina, Marzo 2015



MÉTODOS DE SEGMENTACIÓN DE IMÁGENES DE TEXTURA. OPTIMIZACIÓN DEL MÉTODO OTSU. Por Puente, Mónica Patricia se distribuye bajo una [Licencia Creative Commons Atribución-CompartirIgual 2.5 Argentina](https://creativecommons.org/licenses/by-sa/2.5/argentina/).

RESUMEN

La segmentación de imágenes de textura define un procedimiento por el cual a partir de una imagen de interés es posible obtener una partición de la misma, constituida por regiones disjuntas, de tal forma que cada una de ellas resulta homogénea tomando como característica la textura. Se han desarrollado diferentes metodologías de segmentación de imágenes de textura las que comprenden básicamente el desarrollo de dos etapas bien diferenciadas; por un lado, la extracción exacta de las características (rasgos) de los campos aleatorios que generan las texturas a segmentar y por otro, la discriminación entre tales características. Este trabajo, aborda el problema utilizando imágenes de textura sintéticas. Concretamente, propone el ajuste local, de modelos autorregresivos bidimensionales con dos parámetros a las imágenes sintéticas que se desea segmentar y permite generar por cada parámetro una matriz numérica, llamada matriz de parámetro, la que constituye el objeto sobre el cual se detectan cambios que permiten segmentar la imagen desde dos estrategias. La primera se basa en aplicar métodos de umbralización conocidos a las matrices de parámetros, en lugar de aplicarlos directamente sobre la imagen a segmentar. En base a los experimentos realizados, esta metodología logra la segmentación exitosa de imágenes de textura, aún en casos en los que otros métodos clásicos de segmentación por umbrales, aplicados directamente sobre la imagen de entrada, no logran hacerlo. La segunda iniciativa constituye un procedimiento que analiza por filas y columnas las matrices de parámetros. Los datos por fila, al igual que los datos por columna se consideran series de datos indexadas respectivamente, por la posición en la fila o columna. Cambios en el comportamiento de estas series permiten detectar variaciones en la textura de la imagen.

ABSTRACT

Texture image segmentation defines a procedure in which, from an image of interest, it is possible to obtain a partition consisting of disjoint regions in such a way that each of them is homogeneous, taking texture as a main characteristic. Different methodologies have been developed for texture image segmentation which basically comprises the development of two distinct stages; on the one hand, the accurate removal of the characteristics of the random fields that generate textures to be segmented and on the other hand, the discrimination between such features. This paper addresses the problem by using synthetic texture images. Specifically, it proposes the local adjustment of two-dimensional autoregressive models with two parameters to segment synthetic images generating for each parameter a numerical matrix, called parameter matrix. It is this matrix that makes up the object, on which changes segmenting the image are allowed, by following two strategies. The first strategy is based on the application of thresholding methods familiar to parameter matrices instead of applying them on the matrix to be segmented. On the basis of undertaken experiments, this methodology achieves the successful segmentation of texture images, even in cases in which other classical methods of segmentation by thresholds applied directly to the input image, fail to do so. The second strategy is a procedure that examines rows and columns of parameter matrices. According to the position in the row or column, the data row as well as the column data are respectively considered indexed data sets. Changes in the behaviour of these series allow detecting remarkable variations in the texture of the image.

AGRADECIMIENTOS

Quiero expresar mi agradecimiento a la Dra. Silvia Ojeda por su apoyo, buena disposición y ayuda brindada en el transcurso de esta etapa. Por alentarme a seguir adelante y hacerme creer que era capaz de llegar hasta aquí.

A mi querida Facultad de Ciencias Exactas y Naturales de la Universidad Nacional de Catamarca, por haberme permitido crecer y espero poder devolver, en alguna medida, lo que me entrega día a día.

A mis hermanos Diego y Juan Pablo por el incentivo y apoyo, que seguramente, sin saberlo, me dieron el ánimo y seguridad para continuar en los momentos de cansancio.

A mis madres, Nini y Tete por estar a mi lado cuando más necesité, y brindarme su amor incondicional.

A mis amigos Natalio y Sebastián, por el apoyo y empuje. Siempre tendrán un espacio en mi corazón y espero nunca perderlos.

A Daniela por ser la mujer que me ha acompañado durante esta etapa de mi vida, por ser mi consejera, amiga del alma y fiel hombre de compañía ante las derrotas, penas y alegrías. Por aguantarme y frenar cada impulso de abandonar.

Y por supuesto a Dios, que sin Él nada es posible.

ÍNDICE GENERAL

Resumen.....	pág. ii
Abstract.....	pág. iii
Agradecimientos.....	pág. iv
Índice general.....	pág. v
Índice de figuras.....	pág. viii

CAPÍTULO 1:

1.1 Introducción.....	pág. 1
1.2 Imagen física e imagen digital.....	pág. 2
1.3 Procesamiento digital de imágenes – segmentación.....	pág. 6
1.4 Segmentación por Umbralización.....	pág. 8
1.5 Método de Otsu para un umbral óptimo.....	pág. 10

CAPÍTULO 2:

2.1 Introducción.....	pág. 14
2.2 Modelo autorregresivo bidimensional - Reproducción de imágenes de textura.	pág. 15
2.3 Ajuste de modelos AR-2D a imágenes de textura - Segmentación.....	pág. 16
2.4 Estimación por mínimos cuadrados en el modelo AR-2D.	pág. 17
2.5 Aplicación.....	pág. 21
2.6 Ruido en Imágenes.....	pág. 22
2.7 Estimación mínimo cuadrática en el modelo AR-2D con dos parámetros Contaminado.....	pág. 23

CAPÍTULO 3:

3.1 Segmentación de imagen de textura: Método I.....	pág. 26
3.2 Aplicaciones.....	pág. 31
3.2.1 Combinación vertical.....	pág. 31
3.2.2 Combinación Horizontal.....	pág. 35
3.2.3 Combinación diagonal.....	pág. 37
3.2.4 Franja vertical.....	pág. 39
3.2.5 Franja diagonal.....	pág. 43
3.2.6 Tres texturas.....	pág. 46

CAPÍTULO 4:

4.1 Segmentación basada en series temporales ordenadas.....	pág. 51
4.1.1 Introducción.....	pág. 51
4.1.2 Método II.....	pág. 52
4.2 Aplicaciones.....	pág. 54
4.2.1 Imagen Mixta con yuxtaposición vertical de dos texturas.....	pág. 54
4.2.2 Franja diagonal de dos texturas.....	pág. 57
4.2.3 Combinación vertical de tres texturas.....	pág. 59
4.2.4 Cuatro texturas yuxtapuestas.....	pág. 61

<i>CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS</i>	pág. 64
---	---------

<i>BIBLIOGRAFÍA</i>	pág. 66
---------------------------	---------

ANEXOS

ANEXO I: Pseudocódigo del Método Otsu.....	pág. 68
ANEXO II: Pseudocódigo para general imagen sintética de textura.....	pág. 70

ANEXO III: Pseudocódigo para ajustar el modelo AR-2D con dos parámetros a una imagen de textura.....	pág. 71
ANEXO IV: Pseudocódigo del MÉTODO I.....	pág. 72
ANEXO V: Pseudocódigo del MÉTODO II.....	pág. 74

ÍNDICE DE FIGURAS

1.- Imagen física e Imagen digital.....	pág. 3
2.- Matriz que representa una porción de la imagen. Imagen en escala de gris y escala de gris de 0 a 255.....	pág. 5
3.- Intensidad de color de una imagen. Función de división de colores en un cubo RGB.....	pág. 6
4.- Histograma de una imagen $f(x, y)$ con un objeto claro sobre un fondo oscuro.	pág. 9
5.- Representación del modelo AR-2D.....	pág. 16
6.- Ventanas de predicción para el modelo AR-2D fuertemente causal con dos parámetros.	pág. 19
7.- Imagen de textura generada a partir del modelo AR-2D.....	pág. 19
8.- Imagen de textura generada a partir del modelo AR-2D.....	pág. 21
9.- Contaminación de imágenes.	pág. 24
10.- Desplazamiento de la ventana de observación sobre la imagen mixta.....	pág. 28
11.- Bordos a detectar	pág. 30
12.- Yuxtaposición vertical de las texturas.....	pág. 31
13.- Aplicación del método Otsu para la yuxtaposición vertical de dos imágenes de textura	pág. 32
14.- Matrices de parámetros de yuxtaposición vertical de textura.....	pág. 32
15.- Aplicación del método Otsu a las matrices de parámetros.....	pág. 33
16.- Marca de candidatos a borde respecto a las matrices de parámetros.....	pág. 33
17.- Dos áreas de texturas a partir del Método I.....	pág. 34
18.- Yuxtaposición horizontal de texturas.....	pág. 35
19.- Aplicación del método Otsu a la yuxtaposición horizontal de texturas.....	pág. 35
20.- Matrices de parámetros de yuxtaposición horizontal de textura y Aplicación del método Otsu a las matrices de parámetros.....	pág. 36
21.- Marca de candidatos a borde respecto a las matrices de parámetros y	

Dos áreas de texturas a partir del método I.....	pág. 37
22.- Imagen mixta a partir de la yuxtaposición diagonal de dos texturas.....	pág. 37
23.- Matrices de parámetros de yuxtaposición diagonal de textura, Aplicación del método Otsu a las matrices de parámetros, marca de candidatos a borde respecto a las matrices de parámetros y Dos áreas de texturas a partir del método I.....	pág. 38
24.- Combinación de una franja vertical, dos texturas.....	pág. 39
25.- Matrices de parámetros de combinación franja vertical de textura, Aplicación del método Otsu a las matrices de parámetros, marca de candidatos a borde respecto a las matrices de parámetros.....	pág. 39
26.- Subregiones en las matices de parámetros.....	pág. 41
27.- Yuxtaposición de fragmentos.....	pág. 41
28.- Matrices de parámetros de la yuxtaposición de fragmentos.....	pág. 42
29.- Aplicación del método Otsu a las matrices de parámetros de la yuxtaposición de fragmentos.....	pág. 42
30.- Resultado de segmentación de áreas de texturas, a partir del método I.....	pág. 43
31.- Combinación franja diagonal, dos texturas. Matrices de parámetros de combinación franja vertical de textura, Aplicación del método Otsu a las matrices de parámetros, Segmentación producida por el Método I.....	pág. 44
32.- Yuxtaposición de fragmentos de regiones, Matrices de parámetros de la yuxtaposición de fragmentos, Aplicación del método Otsu a las matrices de parámetros de la yuxtaposición de fragmentos.....	pág. 45
33.- Resultado de segmentación de áreas de texturas en combinación diagonal.....	pág. 46
34.- Combinación de tres texturas solapadas verticalmente.....	pág. 47
35.- Matrices de parámetros combinación de tres texturas solapadas verticalmente, Aplicación del método Otsu a las matrices de parámetros y Segmentación producida por el Método I.....	pág. 47
36.- Yuxtaposición de fragmentos de regiones, Matrices de parámetros de la yuxtaposición de fragmentos, Aplicación del método Otsu a las matrices de parámetros de la yuxtaposición de fragmentos.....	pág. 49
37.- Segmentación de la imagen mixta de tres texturas por el método I.....	pág. 50

38.- Imagen mixta de textura (combinación vertical) y matrices de parámetros.....	pág. 54
39.- Gráfica de la fila 100 de la matriz de parámetros $A_{1,0}$	pág. 54
40.- Gráfica de la fila 38 de ambas matrices de parámetros.....	pág. 55
41.- Línea de borde marcada desde el punto de cruce de las dos series temporales..	pág. 56
42.- Series temporales relativas a las columnas de las matrices de parámetros.....	pág. 56
43.- Dos áreas de textura segmentadas por el método II, combinación vertical.....	pág. 57
44.- Yuxtaposición de dos imágenes de textura en una franja diagonal.....	pág. 57
45.- Gráfica de la fila 157 de ambas matrices de parámetros; Gráfica de la columna 60 de ambas matrices y Líneas de borde marcadas por el método II..	pág. 58
46.- Dos áreas de textura segmentadas por el método II, franja diagonal.....	pág. 59
47.- Gráfica de la fila 124 de ambas matrices de parámetros, líneas de borde marcadas desde el cruce de las series temporales y Resultado de la segmentación de tres texturas por el método II.....	pág. 60
48.- Combinación de cuatro texturas.....	pág. 61
49.- Aplicación del Método II a la combinación de cuatro texturas.....	pág. 61
50.- Subregiones distinguidas por el método II.....	pág. 62
51.- Segmentación de cuatro texturas a partir del método II.....	pág. 63

CAPITULO 1

1.1 INTRODUCCIÓN

La textura es una propiedad inherente a todas las superficies. Ella contiene información importante acerca del ordenamiento estructural de la superficie y sus relaciones con el ambiente que la rodea. Aunque el ojo humano está capacitado para reconocer intuitivamente diferentes texturas, ha sido muy difícil definir y analizar esta característica de las imágenes por medios digitales. A pesar de que se ha difundido el uso de la segmentación de texturas para lograr una buena clasificación digital de imágenes, la textura en sí misma constituye aún un concepto abstracto, no existe una definición precisa libre de ambigüedad, ni un planteamiento matemático formal para su caracterización cuantitativa (Gil Rodríguez, REPORTE TÉCNICO Reconocimiento de patrones, 2008).

En este trabajo abordamos el problema de la segmentación de imágenes de textura sintéticas. Al hablar de imágenes sintéticas nos referimos a imágenes generadas computacionalmente, a partir de diferentes modelos estadísticos, los que han demostrado ser capaces de reproducir imágenes de textura. Trabajaremos con imágenes que muestran dos o tres patrones de textura diferentes; dichas texturas estarán presentes en la imagen en bandas o regiones verticales, horizontales o diagonales; para cada imagen se desea hallar la transición entre las texturas presentes; estas transiciones (bordes) serán entonces líneas con tendencia horizontal, vertical o diagonal responsables de indicar que precisamente en esa línea, la textura en la imagen ha cambiado. Se desarrollarán dos estrategias de discriminación de texturas sintéticas, que serán expuestas en detalle en los capítulos 2 y 3, las que constituyen el aporte fundamental de este trabajo. Si bien las imágenes de la vida real pueden presentar una gran variedad de texturas, analizadas localmente sólo presentarán unos pocos patrones, donde los bordes pueden pensarse como líneas aproximadamente horizontales, verticales o diagonales; en esta idea precisamente se basa la posibilidad de aplicación de este método a imágenes reales, la cual no se explora en esta tesis.

A continuación, expondremos conceptos relacionados con los principios sobre los cuales se basa el procesamiento de imágenes digitales, ideas que luego (capítulo 2), serán requeridas, al abordar con mayor detalle el problema de segmentación de imágenes de textura.

1.2 IMAGEN FÍSICA E IMAGEN DIGITAL

Una imagen física es básicamente una representación de un objeto del mundo real. Esta representación puede obtenerse por medio de dispositivos tales como cámaras, microscopios, telescopios y naturalmente por el ojo humano. Un modelo adecuado para manipular imágenes físicas, viene dado por una función bidimensional $f(x, y)$, donde el valor de esta función indica el brillo o nivel de gris de la imagen en el punto o posición del plano (x, y) . En una imagen monocromática $0 \leq f(x, y) \leq L_{max}$, donde $f(x, y) = 0$ corresponde a la ausencia total de luz en la escena y $f(x, y) = L_{max}$, con $L_{max} \in \mathbb{R}^+$, representa la máxima intensidad luminosa. Al intervalo $[0, L_{max}]$ se lo denominará brillo. (Pérez, 2009). Para procesar una imagen física en una computadora se debe discretizar (digitalizar) tanto el rango como el dominio de la función f . Este procedimiento consiste en extraer a partir de un conjunto infinito de elementos un subconjunto finito, de manera que aumentando el número de puntos, el conjunto finito tienda al continuo. La digitalización de la coordenada espacial (x, y) recibe el nombre de *muestreo* de la imagen y la del brillo *cuantificación* del tono o nivel de gris. Así, una *imagen digital monocromática* es una función de dos dimensiones, definida en un subconjunto finito de $\mathbb{Z} \times \mathbb{Z}$ a valores enteros no negativos, obtenida a partir de una imagen física monocromática que ha sido muestreada y cuantificada.

Una imagen es muestreada en un patrón de grilla igualmente espaciada, y cuantificada en idénticos intervalos de amplitud. Así, una imagen digital se verá como un arreglo bidimensional rectangular de valores. Cada elemento de ésta grilla, igualmente espaciada, acompañado por su correspondiente valor cuantificada es llamado elemento de imagen o *píxel*. El concepto de píxel se refiere a una entidad comprendida por la posición espacial en la grilla y por el brillo promedio del área de las muestras de la imagen en dicha

posición. La figura 1 ilustra un ejemplo de digitalización de una imagen a través de muestreo y cuantización.




Figura 1: Imagen física e Imagen digital.

El resultado final puede representarse mediante una matriz con M filas y N columnas de números enteros no negativos, cuyos elementos (ubicación espacial + brillo) son los píxeles de la imagen. Para mayores detalles puede consultarse Gonzalez, Rafael & Woods, Richard, 2002. De acuerdo con la notación descrita una imagen digital será una matriz H de dimensión $M \times N$, siendo M y N números naturales:

$$H = \{h(x,y)\} = \begin{pmatrix} h(1,1) & h(1,2) & \cdots & h(1,N) \\ h(2,1) & h(2,2) & \cdots & h(2,N) \\ \vdots & \vdots & \ddots & \vdots \\ h(M,1) & h(M,2) & \cdots & h(M,N) \end{pmatrix} \quad \begin{array}{l} \text{con } h(x,y) \in \mathbb{N} \cup \{0\} \\ 1 \leq x \leq M; 1 \leq y \leq N \end{array}$$

El rango de la función $h(x, y)$ será el conjunto:

$$R = \{ 0, 1, 2, \dots, L - 1 \}$$

Donde L es un número natural. R es la discretización del intervalo original $[0, L_{max}]$ de tonos de gris de la imagen física. Los valores de M y N y el número L de niveles de gris suelen ser potencias de 2 para facilitar su representación binaria. Entonces para los L tonos de gris se necesitan n bits, siendo $L = 2^n$. Por ejemplo, para 256 tonos de gris se necesitarán 8 bits de manera que el vector binario (0,0,0,0,0,0,0,0) representa al negro y (1,1,1,1,1,1,1,1) al blanco. El número de bits requeridos para almacenar a la imagen H (imagen física ya digitalizada), es $M \times N \times n$. Como la representación matricial anterior es una aproximación a una imagen física, conforme mayores sean los valores de los parámetros M, N y L , se conseguirá una mejor resolución (grado de detalle en la percepción de la imagen física).

Podemos clasificar a las imágenes digitales en: binarias, imágenes en escala de gris o monocromáticas e imágenes a color. Las imágenes binarias son las más sencillas, pues presentan sólo dos valores posibles de brillo; 0, que representa al color negro y 1 al color blanco; estos son los únicos colores presentes en la imagen. Éste tipo de imagen es también llamada 1bit/pixel. Las imágenes en escala de gris son conocidas como monocromáticas o de un solo color. Las más usadas contienen datos de 8 bits/pixel, es decir que se tienen en total 256 tonos de gris, donde 0 representa al color negro, 255 al color blanco y con los números naturales que van de 1 a 254 se representan las diferentes tonalidades de gris restantes. En éste trabajo se utilizarán imágenes monocromáticas. La Figura 2 muestra un ejemplo de este tipo de imágenes.




Figura 2: Matriz que representa una porción de la imagen. Imagen en escala de gris y escala de gris de 0 a 255. (Imagen adquirida por el autor).

Las imágenes digitales a color están regidas por los mismos conceptos de muestreo y cuantificación que las imágenes en escala de gris. Sin embargo, en lugar de un único valor de brillo que expresa el nivel de gris, los píxeles de las imágenes a color están cuantificados usando tres componentes (bandas), que tendrán distinto significado según el modelo o espacio de color utilizado. Un espacio de color es una representación matemática del conjunto de colores que permite la especificación de un color de manera estándar. Los más conocidos son RGB, usado en los gráficos por computador; CMY ó CMYK, usados en sistemas de impresión (Fernández López, 2014). En el modelo RGB los tonos que intervienen son el rojo, el verde y el azul. La intensidad se representa por medio de un vector con tres componentes donde cada componente asume valores entre 0 y 255. El color visualizado en una posición (x, y) será el resultado de combinar los valores de las tres bandas dadas para esta posición, en la proporción indicada por esos valores. El modelo RGB se basa en las coordenadas cartesianas (ver Figura 3).

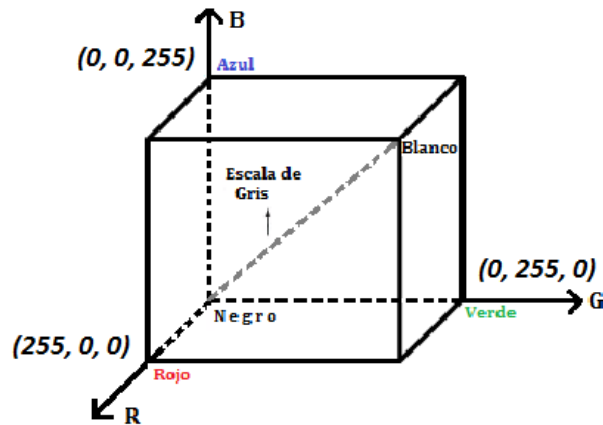


Figura 3: Intensidad de color de una imagen. Función de división de colores en un cubo RGB.

Este tipo de imágenes contiene $3 \times 8\text{bits/pixel}$ un pixel para cada color. La diagonal representa la escala de gris (nivel de intensidad) en un rango que incluye a todos los números enteros pertenecientes al intervalo $[0, 255]$. Además en cada punto de esta diagonal, los colores primarios tienen la misma proporción y se obtiene siempre un tono de gris.

1.3 PROCESAMIENTO DIGITAL DE IMÁGENES - SEGMENTACIÓN

El procesamiento digital de imágenes (PDI) puede definirse como el conjunto de técnicas que se aplican a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información (Proakis, J. y Manolakis, D., 1999). El análisis digital de imágenes (ADI) un conjunto de técnicas destinadas a la extracción de información desde una imagen. El constante crecimiento tecnológico de las últimas décadas ha llevado a la comunidad científica a desarrollar grandes avances en el PDI como en el ADI, tanto en los aspectos teóricos como en las aplicaciones. Estos desarrollos se ven reflejados en una gran variedad de áreas, tales como telecomunicaciones, radiodifusión, imágenes médica, robótica, biología, teledetección, artes gráficas, y otras ramas científicas (Chuvieco, 1990), (Gil Rodríguez, REPORTE TÉCNICO Reconocimiento de patrones, 2008), (Fernández López, 2014), (Bronzino, 2006), (Jesus Martínez-Gomez, 2009). Dentro de las operaciones más

comunes en PDI se encuentran las transformaciones geométricas, corrección de color y del ADI la segmentación, reconocimiento de patrones, clasificación, etc. En lo que se refiere a la segmentación la separación de diferentes clases de píxeles (objetos o secciones) que componen una imagen digital, se lleva a cabo buscando que estas clases sean homogéneas en relación a uno o varios atributos, por ejemplo la textura. En este trabajo se plantea el problema de segmentar imágenes sintéticas en base al atributo de la textura. La idea central es proponer mecanismos capaces de producir una segmentación acertada de este tipo de imágenes, como una alternativa de optimización y mejoramiento de procedimientos existentes.

Existen tres grandes grupos en los que pueden encuadrarse las principales técnicas de segmentación (Gil Rodríguez, 2011):

- Segmentación por Umbralización.
- Segmentación basada en transiciones.
- Segmentación por Crecimiento de Regiones.

En la **segmentación por umbralización** se desea resaltar regiones de características similares, mediante la clasificación de píxeles o grupos de píxeles. Las técnicas de umbralización buscan obtener un valor de umbral que permita binarizar a la imagen separando adecuadamente el fondo y el objeto a separar. Este tema se abordará detalladamente en la sección 1.4.

Por otro lado, la **segmentación basada en transiciones** persigue el aislamiento de los objetos del resto de la imagen, previa identificación de los píxeles que configuran los bordes de dichos objetos. De esta manera, queda definida la forma del objeto y, por consiguiente, los píxeles que lo integran.

La **segmentación por crecimiento de regiones**, es un procedimiento iterativo que se basa en unir regiones adyacentes que cumplan ciertos criterios, por ejemplo nivel de brillo, varianza de los niveles de gris de la región, textura de la región, etc. Comúnmente, los criterios utilizados se refieren a propiedades de proximidad y homogeneidad de los píxeles

considerados, considerándose que píxeles cercanos con intensidades similares corresponden al mismo objeto. El proceso de segmentación finaliza cuando no se encuentran más píxeles que cumplan la condición especificada.

Un estudio exhaustivo del estado del arte de la segmentación de imágenes puede verse en Gil Rodríguez, Evaluación de calidad en la segmentación de imágenes, 2011 y en otros trabajos (Gonzalez, Rafael & Woods, Richard , 2002), (Brais Perez Prol y Javier Remeseiro Reguero, 2013) (Visión-Artificial, 2005).

1.4 SEGMENTACIÓN POR UMBRALIZACIÓN

El principio que rige la segmentación por umbralización es la similitud del nivel de gris entre los píxeles pertenecientes a un grupo de píxeles, que llamaremos objeto y sus diferencias respecto al resto.

Esta técnica de segmentación trata de determinar un valor de intensidad T llamado umbral, que separa las regiones deseadas. La segmentación se logra agrupando, por un lado, todos los píxeles cuyo valor de intensidad es menor que el umbral y, por otro, los píxeles con valores de intensidad mayor que el umbral (González Martínez, 2013). La dinámica del método hace que el proceso de umbralización sea muy rápido computacionalmente pues se trata, simplemente, de recorrer secuencialmente todos los píxeles de la imagen y seleccionar aquellos que son mayores en intensidad (o menores) que un umbral de intensidad prefijado (Federico Cristina, Sebastián H. Dapoto, Verónica Artola, Claudia Russo, Graciela Viegas, 2009). El punto clave en esta técnica es la elección del valor umbral apropiado. Esto se puede realizar de forma manual, aunque habitualmente se necesita un método que permita calcular este valor de forma automática. Precisamente, la etapa más difícil es encontrar el valor correcto del umbral.

El histograma de la imagen será una de las herramientas de importancia para definir el valor umbral, ya que la mayoría de las técnicas de umbralización se basan en estadísticas sobre el histograma unidimensional de una imagen. También se utiliza la matriz de co-ocurrencia de una imagen (Juan S. Botero Valencia y A. Restrepo Martínez, 2010). En

general, para localizar los umbrales se pueden usar procedimientos paramétricos y no paramétricos. En los paramétricos, la distribución de los niveles de gris de una clase de objeto lleva a encontrar los umbrales. En los procedimientos no paramétricos, los umbrales se obtienen de forma óptima de acuerdo a algún criterio.

A través del histograma se obtiene una gráfica donde se muestra el número de píxeles por cada nivel de gris que aparece en la imagen. Donde los picos a menudo indican la presencia de zonas homogéneas y los valles establecen los umbrales de separación (ver Figura 4).




Figura 4: Histograma de una imagen $h(x, y)$ con un objeto claro sobre un fondo oscuro (o viceversa).

(Gonzalez, Rafael & Woods, Richard , 2002).

En una imagen donde existe un objeto claro sobre un fondo oscuro o viceversa se da el caso más sencillo de segmentación por umbralización; basta elegir un umbral dentro de los niveles de gris representado por un valor mínimo de frecuencia entre los máximos valores del histograma. Todos los niveles de gris menores al umbral calculado se convertirán en negro y todos los mayores en blanco después de la binarización proceso del que hablaremos a continuación

A partir de un umbral, T , la imagen en escala de grises, $H = \{h(x, y)\}_{1 \leq x \leq M, 1 \leq y \leq N}$, se transforma en una nueva imagen binarizada $G = \{g(x, y)\}_{1 \leq x \leq M, 1 \leq y \leq N}$, etiquetando con 1 los píxeles que en intensidad son mayores al umbral T y con 0 a aquellos cuyos valores de intensidad son menores o iguales que T . Así:

$$g(x, y) = \begin{cases} 1 & \Leftrightarrow h(x, y) > T \\ 0 & \Leftrightarrow h(x, y) \leq T \end{cases}$$

El umbral depende de H , o de alguna propiedad local de los valores de intensidad $h(x, y)$, y también de su propia posición:

$$T = T(H, h(x, y), (x, y))$$

Si el umbral sólo depende de H se dice que es un **umbral global**; en el caso de que además dependa de alguna propiedad de los valores $h(x, y)$, por ejemplo, el valor medio de los píxeles vecinos en una vecindad de tamaño fijo, el umbral es denominado **local**; y si depende también de la posición (x, y) del píxel considerado, se denominará **dinámico**.

Si bien existen diferentes métodos para hallar un umbral, tales como P-Tile Method, Isodata Algorithm, Background-symmetry algorithm, Triangle algorithm (Brais Perez Prol y Javier Remeseiro Reguero, 2013), uno de los métodos más aplicados a la hora de segmentar por umbralización una imagen donde se destaca una clara diferencia entre los objetos a extraer respecto del fondo de la escena, es el método Otsu (González Martínez, 2013), (Ping-Sung Liao, Tse-Sheng Chen and Pau-Choo Chung, 2001). La importancia del método de Otsu radica en que es automático, es decir, no necesita supervisión ni información previa de la imagen antes de su aplicación. Este procedimiento calcula el valor umbral de forma que la dispersión (distancia entre los valores de intensidad respecto a un valor medio) dentro de cada clase sea lo más pequeña posible, pero al mismo tiempo la dispersión entre diferentes clases sea lo más alta posible. Para ello se calcula el cociente entre ambas varianzas y se busca un valor umbral tal que este cociente sea máximo (González Martínez, 2013).

1.5 MÉTODO DE OTSU PARA UN UMBRAL ÓPTIMO

Sea H una imagen digital, matriz de dimensión $M \times N$, tal que cada uno de sus elementos es un número entero entre 0 y $L - 1$ (L natural, potencia de 2). Si el número de píxeles con nivel de gris i se denota como n_i , la frecuencia de ocurrencia del nivel de gris i en la imagen está dada por:

$$p_i = \frac{n_i}{M \times N}.$$

En el caso de la umbralización en dos niveles de una imagen, los píxeles son divididos en dos clases: C_1 con niveles de gris $[0, \dots, t]$ y C_2 con niveles de gris $[t + 1, \dots, L - 1]$. Entonces, la distribución de frecuencia de los niveles de gris para las dos clases es:

$$C_1 = \left\{ \frac{p_1}{\omega_1(t)}, \dots, \frac{p_t}{\omega_1(t)} \right\} \quad \text{y} \quad C_2 = \left\{ \frac{p_{t+1}}{\omega_2(t)}, \dots, \frac{p_L}{\omega_2(t)} \right\}$$

Donde:

$$\omega_1(t) = \sum_{i=1}^t p_i \quad \omega_2(t) = \sum_{i=t+1}^L p_i = 1 - \sum_{i=1}^t p_i$$

Por otro lado si indicamos como μ_1 y μ_2 respectivamente a la media de intensidad en cada clase, tenemos:

$$\mu_1 = \sum_{i=1}^t \frac{i \cdot p_i}{\omega_1(t)} \quad \mu_2 = \sum_{i=t+1}^L \frac{i \cdot p_i}{\omega_2(t)}$$

Sea μ la intensidad media de toda la imagen. Es sencillo demostrar que:

$$\omega_1 \cdot \mu_1 + \omega_2 \cdot \mu_2 = \mu \quad \text{y} \quad \omega_1 + \omega_2 = 1$$

Otsu definió la varianza entre clases de una imagen umbralizada como:

$$\sigma_B^2(t) = \omega_1(t) \cdot (\mu_1 - \mu)^2 + \omega_2(t) \cdot (\mu_2 - \mu)^2$$

Este valor mide la dispersión entre los valores de intensidad de las dos clases C_1 y C_2 definidas al tomar como valor umbral el valor de intensidad t .

Para una umbralización de dos niveles, Otsu verificó que el umbral óptimo t^* se elige de manera que σ_B^2 sea máxima; esto es:

$$t^* = \max\{\sigma_B^2(t)\} \quad 0 \leq t \leq L - 1$$

Este paso persigue el objetivo inicial de dispersar lo máximo posible los niveles de intensidad de las dos clases.

El método de Otsu puede ser extendido por ejemplo, para tres clases; habría en este caso dos umbrales t_1^* y t_2^* capaces de maximizar la varianza entre clases, es decir:

$$\{t_1^*, t_2^*\} = \max\{\sigma_B^2(t_1, t_2)\} \quad \text{con } 0 \leq t_1 < t_2 < L - 1$$

La varianza σ_B^2 es entonces función de dos variables t_1 y t_2 , y el conjunto óptimo de los umbrales t_1^* y t_2^* se selecciona mediante la maximización de σ_B^2 .

Entonces, la imagen segmentada será:

$$g(x, y) = \begin{cases} a & \Leftrightarrow h(x, y) \leq t_1^* \\ b & \Leftrightarrow t_1^* < h(x, y) \leq t_2^* \\ c & \Leftrightarrow h(x, y) > t_2^* \end{cases}$$

El método Otsu puede extenderse a múltiples umbrales. Asumiendo que hay $R - 1$ umbrales, $\{t_1, t_2, \dots, t_{R-1}\}$, los cuales dividen a la imagen en R clases: C_1 para $[0, \dots, t_1]$, C_2 para $[t_1 + 1, \dots, t_2]$, ..., C_i para $[t_{i-1} + 1, \dots, t_i]$, ..., y C_R para $[t_{R-1}, \dots, L - 1]$, los umbrales óptimos $\{t_1^*, \dots, t_i^*, \dots, t_{R-1}^*\}$ se eligen maximizando σ_B^2 como sigue:

$$\{t_1^*, \dots, t_i^*, \dots, t_{R-1}^*\} = \max\{\sigma_B^2(t_1, \dots, t_i, \dots, t_{R-1})\} \quad \text{con } 0 \leq t_1 < \dots < t_{R-1} < L - 1$$

Donde:

$$\sigma_B^2 = \sum_{k=1}^R \omega_k \cdot (\mu_k - \mu)^2$$

Con:

$$\omega_k(t) = \sum_{i \in C_k} p_i \quad \text{y} \quad \mu_k = \sum_{i \in C_k} \frac{i \cdot p_i}{\omega_k}$$

ω_k es conocido como momento acumulado de orden cero de la k -ésima clase C_k y el numerador de la última expresión es conocido como momento acumulado de primer orden de la k -ésima clase C_k ; esto es:

$$\mu_k = \sum_{i \in C_k} i \cdot p_i$$

El pseudocódigo de programación del método Otsu puede verse en el Anexo I.

Una de las desventajas del método Otsu es que a medida que el número de clases en la imagen aumenta, se requerirá más tiempo para escoger los umbrales adecuados. Además en el caso de imágenes de textura, proporciona resultados inapropiados pues distribuciones espaciales muy distintas pueden tener histogramas muy similares. Precisamente en este trabajo se pretende optimizar el método, complementándolo con otros procedimientos a los efectos de conseguir segmentar imágenes de textura con buenos resultados.

CAPITULO 2

2.1 INTRODUCCIÓN

Como se señaló en el capítulo anterior, la textura constituye una propiedad inherente a todas las superficies y contiene información importante acerca del ordenamiento estructural de estas superficies y sus relaciones con el ambiente que las rodea. Asimismo la textura en una imagen se refiere a la magnitud y frecuencia con la que se suceden los cambios de tono en una región de la imagen. Se percibe como el contraste entre los elementos y se manifiesta en la aparente rugosidad o suavidad del espacio. Castleman en el año 1996 la definió como un atributo de las imágenes que representa la disposición espacial de los niveles de gris de los píxeles en una región (Castleman, 1996).

Diferentes métodos de análisis de textura se han utilizados con resultados tangibles en muchas aplicaciones de teledetección, tales como cartografía, análisis de expansión urbana, clasificación de bosques, caracterización de la vegetación y estudios del paisaje. (Sali, E. y Wolfson, H., 1992), (Andrzej Materka y Michal Strzelecki, 1998). Por otra parte, muchos estudios referidos a la segmentación de imágenes digitales se basan en el análisis de las diferencias en la distribución espacial de los niveles de gris de los píxeles vecinos; esto es, las diferencias halladas en la textura (Gil Rodríguez, REPORTE TÉCNICO Reconocimiento de patrones, 2008). Así, la segmentación de imágenes de textura comprende básicamente el desarrollo de dos etapas bien diferenciadas; por un lado, la extracción exacta de las características (rasgos) de **los campos aleatorios** que generan las texturas a segmentar y por otro, la discriminación entre tales características. Entre las herramientas utilizadas para trabajar en el desarrollo de la primera etapa podemos mencionar: el Modelo Autorregresivo (Oe, 1993), la matriz de co-ocurrencia (Xie, 2008), la Transformada Wavelet (Andrzej Materka y Michal Strzelecki, 1998), las máscaras de filtros direccionales (por ejemplo filtros Gabor) (B.S. Manjunathi and W.Y. Ma, 1996) y los predictores lineales (Haindl, 1991), entre otros. En este trabajo recurriremos al estudio y

aplicación de modelos autorregresivos bidimensionales con dos parámetros. La próxima subsección se explyea en este sentido.

2.2 MODELO AUTORREGRESIVO BIDIMENSIONAL - REPRODUCCIÓN DE IMÁGENES DE TEXTURA

Una de las herramientas exitosas para hacer frente al problema de la extracción de las características de textura consiste en modelar la imagen a partir de un modelo autorregresivo bidimensional (AR-2D). Esta estructura matemática ha demostrado eficacia para reproducir localmente las características dinámicas de una imagen de textura (Ojeda, S., Vallejos, R., Bustos, O., 2010). El modelo constituye la extensión a dos dimensiones de un proceso autorregresivo usado en el análisis de series temporales y dicha extensión permite expresar las características dinámicas de datos discretos en un plano de dos dimensiones (Whittle, 1954), (Leiva, 1995) .Según este modelo, el tono de gris de una imagen en la posición ij puede ser expresada localmente como:

$$x_{i,j} = \sum_{(p,q) \in D} \sum a_{p,q} x_{i-p,j-q} + \eta_{i,j}, \quad (1)$$

Con $a_{0,0} = 0$, donde D es la región rectangular definida por:

$$D = \{(p, q) \in Z^2 / 0 \leq p \leq P, 0 \leq q \leq Q\}$$

Siendo P y Q números enteros positivos, y $\{\eta_{i,j}\}_{(i,j) \in Z^2}$ es un proceso de ruido blanco. Es decir:

- a) $E(\eta_{i,j}) = \mu = 0 \quad \forall (i, j) \in Z^2$.
- b) $Var(\eta_{i,j}) = \sigma^2 < \infty \quad \forall (i, j) \in Z^2$.
- c) $Cov(\eta_{i,j}, \eta_{k,l}) = 0 \quad \forall (i, j) \neq (k, l)$.

Además se dice que el proceso $\eta_{i,j}$ es Gaussiano si $\eta_{i,j} \sim N(0, \sigma^2) \quad \forall (i, j) \in Z^2$.

El modelo así definido se denomina modelo causal, donde el máximo entre P y Q define el orden del modelo. Además para que el modelo sea estacionario, se requiere que:

$$\sum_{(p,q) \in D} |a_{p,q}| < 1$$

La figura 5 representa un esquema del modelo AR-2D donde puede observarse cómo el valor del píxel en la posición (i, j) de la imagen es calculado como una combinación lineal de las observaciones en las posiciones de los $(P + 1) \times (Q + 1) - 1$ píxeles vecinos (donde los escalares son los parámetros a estimar), más el valor dado por un ruido aleatorio.




Figura 5: Representación del modelo AR-2D. El valor de intensidad de un píxel de posición (i, j) , se obtiene como una combinación lineal de los píxeles en D con escalares dados por los parámetros $a_{p,q}$ más el aporte del proceso de ruido blanco $\{\eta_{i,j}\}_{(i,j) \in \mathbb{Z}^2}$.

2.3 AJUSTE DE MODELOS AR-2D A IMÁGENES DE TEXTURA - SEGMENTACIÓN

Para realizar la segmentación de imágenes de textura, proponemos partir de la idea sugerida en Ojeda et al. (Ojeda, S., Vallejos, R., Bustos, O., 2010). Estos autores ajustan localmente modelos AR-2D con dos parámetros a la imagen, obteniendo una estructura a la que se denomina “imagen ajustada”. Los residuos de este ajuste permiten definir una estructura final (imagen diferencia o imagen residual), la cual posee interesantes características de textura, ya que destaca y distingue los bordes o líneas de cambio en la

textura de la imagen original. En el caso de utilizar modelos AR-2D Gaussianos, los parámetros del modelo pueden estimarse tanto por el método de máxima verosimilitud, como por el método de mínimos cuadrados (la estimación de los parámetros en este caso, es la misma). En este trabajo y a los efectos de facilitar el cálculo, aplicaremos el método de mínimos cuadrados (Oe, 1993).

2.4 ESTIMACIÓN POR MÍNIMOS CUADRADOS EN EL MODELO AR-2D

Si los valores estimados $\hat{x}_{i,j}$ de $x_{i,j}$ por el modelo están dados por:

$$\hat{x}_{i,j} = \sum_{p=0}^P \sum_{q=0}^Q a_{p,q} x_{i-p,j-q} \quad a_{0,0} = 0 \quad (2)$$

Entonces el error $e_{i,j}$ entre el verdadero valor de $x_{i,j}$ y el valor estimado $\hat{x}_{i,j}$ es:

$$e_{i,j} = x_{i,j} - \hat{x}_{i,j}$$

$$e_{i,j} = x_{i,j} - \sum_{p=0}^P \sum_{q=0}^Q a_{p,q} x_{i-p,j-q} \quad (3)$$

La suma de los errores al cuadrado, S , está dada por:

$$S = \sum_{(i,j) \in D} e_{i,j}^2$$

$$S = \sum_{(i,j) \in D} \left(x_{i,j} - \sum_{p=0}^P \sum_{q=0}^Q a_{p,q} x_{i-p,j-q} \right)^2 \quad (4)$$

Los coeficientes (candidatos) que minimizan S se pueden obtener derivando parcialmente (4) con respecto a cada parámetro e igualando a cero:

$$\frac{\partial S}{\partial a_{k,l}} = 0 \quad (5)$$

Donde $k = 0, \dots, P$; $l = 0, \dots, Q$ con $(k, l) \neq (0, 0)$. Se obtienen de esta manera $(P + 1) \times (Q + 1) - 1$ ecuaciones, con el mismo número de incógnitas. Es decir: Para todo $k = 0, \dots, P$, $l = 0, \dots, Q$, donde k y l no son nulos simultáneamente:

$$\frac{\partial S}{\partial a_{k,l}} = \sum_{(i,j) \in D} \left(x_{i,j} - \sum_{p=0}^P \sum_{q=0}^Q a_{p,q} x_{i-p,j-q} \right) (-x_{i-k,j-l}) = 0 \quad (6)$$

Una vez verificadas condiciones de segundo orden, la solución de este sistema proporciona las estimaciones mínimo-cuadráticas de los parámetros del modelo propuesto. En el caso en que el modelo se asuma con un gran número de parámetros, el proceso de estimación puede ser extremadamente complejo. Con el fin de representar imágenes utilizando modelos que son estadísticamente tratables, es común suponer que una imagen puede ser representada utilizando un escaso número de parámetros, lo cual parece ser un supuesto bastante ajustado a la realidad (Ojeda, S., Vallejos, R., Bustos, O., 2010). En particular y según lo desarrollado en Ojeda et al. (Ojeda, S. y Britos, G., 2013) el modelo AR-2D fuertemente causal, con dos parámetros, es adecuado para reproducir localmente las características dinámicas de una imagen de textura. La expresión matemática de este modelo es la siguiente:

$$x_{i,j} = \sum_{p=0}^1 \sum_{q=0}^1 a_{p,q} x_{i-p,j-q} + \eta_{i,j}$$

Con $a_{1,1} = 0$, $\{\eta_{i,j}\}_{(i,j) \in \mathbb{Z}^2}$ proceso de ruido blanco Gaussiano y los requerimientos mencionados en la sección 2.2. Así,

$$x_{i,j} = a_{1,0}x_{i-1,j} + a_{0,1}x_{i,j-1} + \eta_{i,j} \quad (7)$$




Figura 6: Ventanas de predicción para el modelo AR-2D fuertemente causal con dos parámetros.

Para mostrar la versatilidad del modelo dado por (7) para reproducir imágenes de textura, se generaron diferentes imágenes variando los valores de los parámetros (Figura 7). Se puede visualizar cómo cambios en los valores de los parámetros del modelo, producen imágenes de textura diferentes. El pseudocódigo utilizado para generar estas imágenes se presenta en el anexo II.




Figura 7: Imagen de textura generada a partir del modelo AR-2D: a) $a_{1,0} = 0,5$ y $a_{0,1} = 0,49$; b) $a_{1,0} = 0,01$ y $a_{0,1} = 0,02$; c) $a_{1,0} = 0,01$ y $a_{0,1} = 0,9$; d) $a_{1,0} = 0,9$ y $a_{0,1} = 0,02$.

Entonces para el caso particular del modelo dado por (7):

$$e_{i,j} = x_{i,j} - a_{1,0}x_{i-1,j} - a_{0,1}x_{i,j-1}$$

Luego, la suma de los cuadrados de los errores S , está dado por:

$$S(a_{1,0}; a_{0,1}) = \sum_{(i,j) \in D} e_{i,j}^2 = \sum_{(i,j) \in D} (x_{i,j} - a_{1,0}x_{i-1,j} - a_{0,1}x_{i,j-1})^2$$

Donde W es la ventana de observación y de ajuste local de la imagen. Para minimizar la suma de los cuadrados de los errores se plantea el siguiente sistema de dos ecuaciones con dos incógnitas:

$$\frac{\partial S}{\partial a_{1,0}} = \sum_{(i,j) \in D} (x_{i,j} - a_{1,0}x_{i-1,j} - a_{0,1}x_{i,j-1}) (-x_{i-1,j}) = 0$$

$$\frac{\partial S}{\partial a_{0,1}} = \sum_{(i,j) \in D} (x_{i,j} - a_{1,0}x_{i-1,j} - a_{0,1}x_{i,j-1}) (-x_{i,j-1}) = 0$$

Luego:

$$\begin{cases} \sum_{(i,j) \in D} x_{i,j} \cdot x_{i-1,j} = a_{1,0} \sum_{(i,j) \in D} (x_{i-1,j})^2 + a_{0,1} \sum_{(i,j) \in D} x_{i,j-1} \cdot x_{i-1,j} \\ \sum_{(i,j) \in W} x_{i,j} \cdot x_{i,j-1} = a_{1,0} \sum_{(i,j) \in D} x_{i-1,j} \cdot x_{i,j-1} + a_{0,1} \sum_{(i,j) \in D} (x_{i,j-1})^2 \end{cases}$$

Sea $A = \sum_{(i,j) \in D} x_{i,j} \cdot x_{i-1,j}$; $B = \sum_{(i,j) \in D} (x_{i-1,j})^2$; $C = \sum_{(i,j) \in D} x_{i,j-1} \cdot x_{i-1,j}$; $D = \sum_{(i,j) \in D} x_{i,j} \cdot x_{i,j-1}$ y $E = \sum_{(i,j) \in D} (x_{i,j-1})^2$, el sistema anterior se convierte en:

$$\begin{cases} A = a_{1,0}B + a_{0,1}C \\ D = a_{1,0}C + a_{0,1}E \end{cases} \quad (8)$$

Resolviendo el sistema de ecuaciones (8) y verificando condiciones de segundo orden, se obtendrá la estimación mínimo cuadrática del vector de parámetros $(a_{1,0}; a_{0,1})$.

2.5 APLICACIÓN

A continuación se aplicó el procedimiento descrito en la sección anterior, para lo cual se consideraron tres modelos AR-2D con dos parámetros como en (7). En los tres casos el ruido proviene de una distribución normal con media nula y varianza igual a 1. Respectivas realizaciones de cada uno de estos modelos se presentan en la Figura 8.

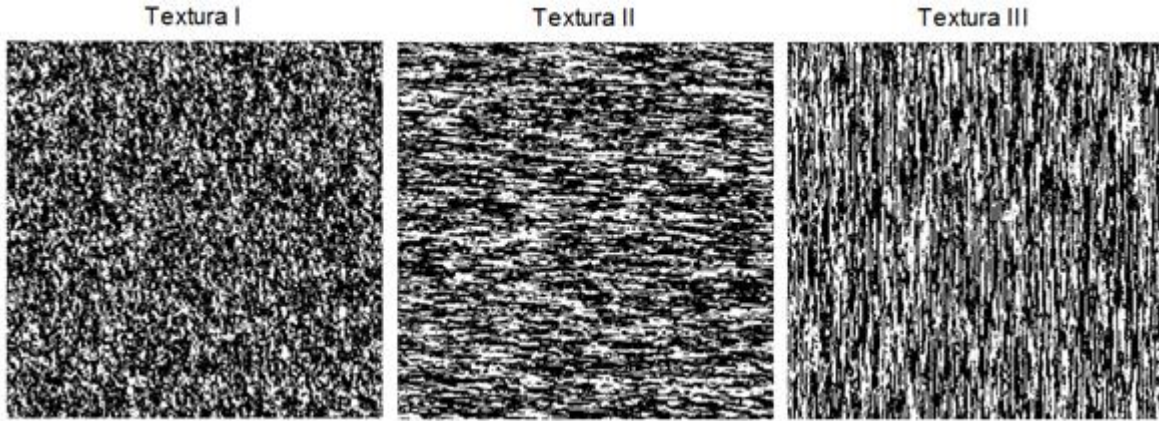


Figura 8: Imagen de textura generada a partir del modelo AR-2D: a) $a_{1,0} = 0,5$ y $a_{0,1} = 0,2$; b) $a_{1,0} = 0,07$ y $a_{0,1} = 0,8$; c) $a_{1,0} = 0,9$ y $a_{0,1} = 0,01$; tres imágenes generadas.

Para cada modelo, se generaron 100 realizaciones (imágenes de textura) de tamaño 256×256 y se estimaron los parámetros $a_{1,0}$ y $a_{0,1}$ del modelo. Luego, para cada parámetro se obtuvo como estimación final el valor promedio de las 100 estimaciones logradas. Los resultados obtenidos se muestran en la Tabla 1. Para cuantificar el error en la estimación de los parámetros, para cada parámetro presente en cada modelo, se calculó la diferencia en valor absoluto entre el verdadero valor del parámetro y cada una de las estimaciones, promediando estas diferencias. Es decir:

$$D_{1,0} = \sum_{n=1}^{100} \frac{|a_{1,0} - \hat{a}_{1,0,n}|}{100} \quad \text{y} \quad D_{0,1} = \sum_{n=1}^{100} \frac{|a_{0,1} - \hat{a}_{0,1,n}|}{100}$$

Estos valores son informados en la Tabla 1.

	Textura I		Textura II		Textura III	
	$a_{1,0}$	$a_{0,1}$	$a_{1,0}$	$a_{0,1}$	$a_{1,0}$	$a_{0,1}$
Parámetros	0,2000	0,5000	0,8000	0,0700	0,0100	0,9000
Promedio de Estimaciones	0,2023	0,4925	0,8028	0,0681	0,0096	0,8958
Error	$D_{1,0}$	$D_{0,1}$	$D_{1,0}$	$D_{0,1}$	$D_{1,0}$	$D_{0,1}$
	0,0023	0,0075	0,0028	0,0019	0,0004	0,0042

Tabla 1: Error de estimación de los parámetros del modelo AR-2D ajustado a las imágenes de textura

El error en la estimación de los parámetros resultó ser menor a 0,01. Se puede concluir entonces que el modelo hasta aquí propuesto es adecuado para ajustar un modelo AR-2D a una imagen sintética de textura.

2.6 RUIDO EN IMÁGENES

Normalmente durante el proceso de adquisición o transmisión, las imágenes digitales pueden corromperse, presentando distorsiones, que pueden modelarse según diferentes esquemas de contaminación o ruido. Se define al ruido como toda aquella señal no deseada que perturba la señal original (Gonzalez, Rafael & Woods, Richard , 2002). Otra definición de ruido es cuando el valor de un píxel de una imagen no se corresponde con la realidad (Simó, 2012).

Uno de los ruidos más comunes **en simulación** es el impulsivo o “sal y pimienta”. Éste altera aleatoriamente el valor de un grupo de píxeles. Habrá píxeles en la imagen con valores de intensidad muy diferentes de los niveles de intensidad de los píxeles de su entorno. Suele aparecer en forma de impulsos blancos o negros, es decir se trata de píxeles “encendidos” y “apagados”. Toman valores máximos y mínimos, no teniendo relación con píxeles vecinos. Este ruido afectará a la imagen según el valor de su función de densidad de probabilidad. (Fernández García, 2013). Si $h(x, y)$ es el valor del píxel de posición (x, y) en la imagen original, el valor de intensidad de este píxel en la imagen contaminada con ruido impulsivo, estará dado por

$$g(x, y) = \begin{cases} h(x, y) & \text{con probabilidad } 1 - d \\ \eta(x, y) & \text{con probabilidad } d \end{cases}$$

siendo $0 < d < 1$ Aunque una imagen no haya sido afectada por ruido durante la adquisición, en la transmisión o en el procesamiento, ésta podrá ser degradada mediante algoritmos para simular lo que podría haber ocurrido si el ruido hubiese estado presente.

2.7 ESTIMACIÓN MÍNIMO CUADRÁTICA EN EL MODELO AR-2D CON DOS PARÁMETROS CONTAMINADO


En esta sección se desarrolló un experimento con el propósito de observar los resultados de la estimación mínimo cuadrática de los parámetros en el modelo (7) en el caso de que una imagen sintética de textura se vea afectada por ruido de tipo impulsivo.

Inicialmente se generó una textura (imagen) T de tamaño 256×256 mediante el modelo (7), con parámetros $a_{1,0} = 0.46$ y $a_{0,1} = 0.48$ utilizando un proceso de ruido blanco con media 0 y varianza 1. Luego se contaminó con ruido impulsivo la imagen, considerando diferentes niveles de contaminación d , con $0 < d < 1$, según se indica en la Tabla 2. El ruido afectó a aproximadamente a $d \times (256 \times 256)$ píxeles de la imagen T . Sean $T_{02}, T_{015}, T_{01}, T_{002}, T_{005}$ y T_{001} las imágenes de textura obtenidas contaminando la imagen de textura T con diferentes grados de contaminación, como se muestra en la Tabla 2. Estas imágenes se muestran en la Figura 9

	d	Cantidad de píxeles de la imagen	Cantidad de píxeles afectados
T_{02}	0,2	65536	13107
T_{015}	0,15		9830
T_{01}	0,1		6554
T_{002}	0,02		1311
T_{005}	0,005		328
T_{001}	0,001		66

Tabla 2: Muestra la densidad de contaminación sal y pimienta en la imagen original.

En la columna central se resaltan en un fondo gris los píxeles afectados en la contaminación.



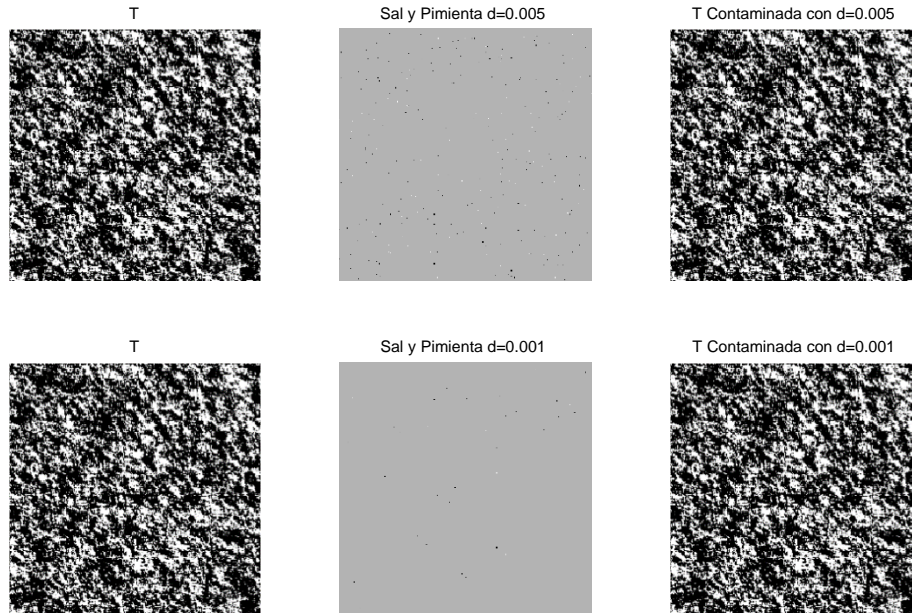


Figura 9: A la izquierda imagen original, en el centro la densidad de contaminación con los píxeles afectados para cada caso y a la derecha la imagen contaminada.

Las estimaciones de los parámetros obtenidas por el método de mínimos cuadrados para T_{02} , T_{015} , T_{01} , T_{002} , T_{005} y T_{001} se muestran en la Tabla 3.

Parámetros	T_{02}	T_{015}	T_{01}	T_{002}	T_{005}	T_{001}	T
$a_{0,1}$	0.4046	0.4169	0.4294	0.4527	0.4578	0.4595	0.4600
$a_{1,0}$	0.4175	0.4290	0.4472	0.4736	0.4786	0.4801	0.4800

Tabla 3: Estimación de los parámetros para imágenes contaminadas con ruido sal y pimienta.

Desde el cuadro puede verse que al comparar los valores verdaderos de los parámetros con sus respectivas estimaciones mínimo cuadráticas:

- A medida que disminuye la proporción de píxeles contaminados, las estimaciones de los parámetros son respectivamente más similares a los verdaderos valores de los parámetros.
- La contaminación del modelo a partir de un proceso de ruido de tipo impulsivo (ruido sal y pimienta), afecta la estimación mínimo cuadrática de los parámetros del modelo.

Capítulo 3

Como se expresó en capítulos anteriores, en esta tesis proponemos dos metodologías para la segmentación de imágenes de textura sintéticas. En ambos procedimientos partimos de una imagen de textura que se desea segmentar y a la cual se ajusta localmente un modelo autorregresivo bidimensional con dos parámetros. Este modelo de ajuste local viene dado por la expresión (7) del Capítulo 2 y los parámetros del modelo varían según la ventana de la imagen en que se realice el ajuste. En este Capítulo presentaremos la primera de las propuestas, la cual optimiza y complementa al método de segmentación por umbrales desarrollado por Otsu (Otsu, 1979) al que llamaremos “Método I”.

3.1 SEGMENTACIÓN DE IMAGEN DE TEXTURA

Método I

Se considera el problema de segmentar una imagen digital, que se llamará imagen mixta, la cual estará constituida por dos o más áreas diferenciadas por su textura.

Sea C una imagen mixta de tamaño $M \times N$ píxeles (M y N números naturales).

$$C = \{c_{ij} / 1 \leq i \leq M, \quad 1 \leq j \leq N\}$$

Sean m y n números naturales, $1 < m < M$ y $1 < n < N$. Asumiremos que en toda subimagen de tamaño $m \times n$ de C , se distinguen a lo sumo dos texturas diferentes. La determinación de los valores de m y n , puede realizarse a partir de diferentes exámenes preliminares sobre la imagen a segmentar, tal como la presencia de cambios en la media y en la varianza de la intensidad de los píxeles en subimágenes a medida que aumenta el tamaño de estas subimágenes.

Sea W_{11} la subimagen o ventana de observación de C , de tamaño $m \times n$ dada por:

$$W_{11} = \{c_{ij} / 1 \leq i \leq m, \quad 1 \leq j \leq n\}$$

Mediante el procedimiento descrito en el Capítulo 2, ajustamos un modelo AD-2D con dos parámetros a W_{11} , estimando el vector de parámetros del modelo $v_{11} = (a_{0,1}^{11}; a_{1,0}^{11})$, mediante $\hat{v}_{11} = (\hat{a}_{0,1}^{11}; \hat{a}_{1,0}^{11})$ (estimación por mínimos cuadrados). Sea t un número natural tal que $t \leq n$ y definamos ahora una nueva ventana de observación de C dada por:

$$W_{12} = \{c_{ij}/1 \leq i \leq m, \quad 1 + t \leq j \leq n + t\}$$

Notemos que W_{12} se obtiene desplazando la ventana de observación W_{11} , t posiciones (columnas de la matriz C) hacia la derecha. En forma similar a lo hecho con W_{11} , ajustamos según el algoritmo del Capítulo 2, un modelo AR-2D con dos parámetros a la subimagen W_{12} , estimando el correspondiente vector de parámetros del modelo $v_{12} = (a_{0,1}^{12}; a_{1,0}^{12})$ mediante $\hat{v}_{12} = (\hat{a}_{0,1}^{12}; \hat{a}_{1,0}^{12})$, estimación obtenida por mínimos cuadrados. El procedimiento continúa hasta construir h subimágenes $W_{11}, W_{12}, \dots, W_{1h}$ de C , y sus respectivas estimaciones de los vectores de parámetros $v_{11}, v_{12}, \dots, v_{1h}$, donde h se calcula tomando la parte entera de $\frac{N-(n-t)}{t}$. Para cada $1 \leq z \leq h$, $v_{1z} = (a_{0,1}^{1z}; a_{1,0}^{1z})$, es el vector de parámetros que surge de ajustar un modelo AR-2D a la subimagen W_{1z} de C , donde,

$$W_{1z} = \{c_{ij}/1 \leq i \leq m, \quad 1 + (z-1)t \leq j \leq n + (z-1)t\}$$

Sea ahora k un número natural, $k \leq m$ y sea l la parte entera de $\frac{M-(m-k)}{k}$. Según el esquema precedente es posible obtener l ventanas de observación (subimágenes de C), $W_{11}, W_{21}, \dots, W_{l1}$. Para cada $1 \leq y \leq l$, W_{y1} estará dada por:

$$W_{y1} = \{c_{ij}/1 + (y-1)k \leq i \leq m + (y-1)k, \quad 1 \leq j \leq n\}$$

En cada ventana se procederá a ajustar un modelo AR-2D con dos parámetros estimándose el vector de parámetros correspondiente.

Entonces, para t, h, k y l como se definieron arriba y para cada par de números naturales y, z con $1 \leq y \leq l$ y $1 \leq z \leq h$, definimos:

$$W_{yz} = \{c_{ij}/1 + (y - 1)k \leq i \leq m + (y - 1)k, \quad 1 + (z - 1)t \leq j \leq n + (z - 1)t\}$$

Mediante el procedimiento descrito en el Capítulo 2, ajustamos un modelo AR-2D con dos parámetros a la subimagen W_{yz} de C , estimando el vector de parámetros $v_{yz} = (a_{0,1}^{yz}; a_{1,0}^{yz})$, mediante el estimador $\hat{v}_{yz} = (\hat{a}_{0,1}^{yz}; \hat{a}_{1,0}^{yz})$ del modelo. La Figura 10 muestra un esquema relacionado con la construcción anterior, a partir del cual se visualiza el recorrido de la imagen mediante ventanas de observación.




Figura 10: Desplazamiento de la ventana de observación sobre la imagen mixta.

Se puede entonces construir dos matrices de dimensión $l \times h$, $A_{0,1}$ y $A_{1,0}$, que llamaremos *matrices de parámetros* (estimados), tal que $A_{0,1}$ es la matriz de todas las primeras componentes de las $l \times h$ estimaciones de los vectores de parámetros y $A_{1,0}$ la de todas las segundas componentes. Más precisamente:

$$A_{0,1} = \begin{pmatrix} \hat{a}_{0,1}^{11} & \dots & \hat{a}_{0,1}^{1h} \\ \vdots & \ddots & \vdots \\ \hat{a}_{0,1}^{l1} & \dots & \hat{a}_{0,1}^{lh} \end{pmatrix} \text{ y } A_{1,0} = \begin{pmatrix} \hat{a}_{1,0}^{11} & \dots & \hat{a}_{1,0}^{1h} \\ \vdots & \ddots & \vdots \\ \hat{a}_{1,0}^{l1} & \dots & \hat{a}_{1,0}^{lh} \end{pmatrix}$$

Dado que el modelo AR-2D es capaz de reproducir y distinguir diferentes patrones de textura (Ojeda, S. y Britos, G., 2013), (Ojeda, S., Vallejos, R., Bustos, O., 2010), (Whittle, 1954), las variaciones en la textura de la imagen C , deberían ser captadas por las matrices de parámetros. La idea que se propone sugiere considerar a $A_{0,1}$ y $A_{1,0}$ como representaciones matemáticas de imágenes ficticias (imágenes de parámetros) para luego

aplicar a estas imágenes el método de segmentación de Otsu y aprovechar esta segmentación para conseguir una segmentación adecuada de la imagen C .

Sea $\hat{a}_{0,1}^{yz}$ un píxel de borde de $A_{0,1}$, detectado a partir de aplicar el método Otsu a $A_{0,1}$; entonces la subimagen W_{yz} (ventana de borde) será una región de la imagen C asociada a píxeles donde cambia la textura en C .

Una vez identificada la ventana de borde W_{yz} , optaremos por clasificar como “candidato a borde” de C al píxel central de dicha ventana. Bajo esta consideración m y n deben ser números impares. Sea este candidato a borde $c_{rs}^{0,1}$, donde $r = \frac{m+1}{2} + (y-1)k$ y $s = \frac{n+1}{2} + (z-1)t$.

En forma análoga procederemos con la matriz $A_{1,0}$, a partir de la cual se clasifican en C nuevos píxeles candidatos a borde que designaremos en general como $c_{ef}^{1,0}$, donde $e = \frac{m+1}{2} + (y-1)k$ y $f = \frac{n+1}{2} + (z-1)t$. Según esta notación el píxel $\hat{a}_{1,0}^{ef}$ es un píxel de borde de la imagen ficticia $A_{1,0}$ y consecuentemente W_{ef} es una subimagen de C tal que su píxel central es el píxel $c_{ef}^{0,1}$.

Analizando por fila la matriz C se pueden presentar las siguientes situaciones:

- 1) Si no existen píxeles en la fila candidatos a borde, entonces la textura es homogénea en la fila.
- 2) Si existe un único candidato a borde, entonces se lo considera punto de borde de la fila.
- 3) Si se distinguen dos o más candidatos a borde, se procede a ordenarlos por la posición en la fila. Luego se los clasifica en grupos, de tal forma que cada grupo esté compuesto por candidatos cuya distancia espacial sea igual o inferior a $m + 1$ píxeles. De cada grupo surgirá un único punto de borde, el cual se puede obtener por distintos procedimientos, entre ellos proponemos alguno de los dos siguientes:
 - i. Llevar a cabo una selección aleatoria de uno de los píxeles entre todos los del grupo, el cual se considerará punto de borde de la fila.

- ii. Otra alternativa posible será, analizar la diferencia en valor absoluto entre, la intensidad de cada candidato a borde y la intensidad promedio de los píxeles de la respectiva ventana (de la cual es centro este candidato a borde), entonces se considerará como borde de la fila a aquel que produce la mayor distancia.

Un análisis similar se puede realizar estudiando la matriz C por columnas. Los resultados de la segmentación por Otsu de las matrices de parámetros pueden ayudar a decidir sobre la conveniencia de procesar los candidatos a borde a partir de un análisis por filas o por columnas de la imagen a segmentar. Si se conoce que en la imagen predominan los bordes verticales, se aconseja un recorrido por filas, en tanto que si la información sobre C es que prevalecen los bordes con tendencia horizontal, se aconseja un recorrido por columnas. Para bordes diagonales o si se desconoce la tendencia del borde, se aconseja llevar a cabo tanto el examen por filas como por columnas, definiendo en cada situación a partir de ambos estudios los bordes o línea de división de texturas (Ver Figura 11).

Con el propósito de distinguir un borde continuo en C , en este trabajo asumiremos $t = k = 1$. Es decir el barrido de la imagen C a partir de las ventanas W_{yz} se realizará pixel a pixel. El pseudocódigo que permite implementar computacionalmente el método propuesto puede verse en el anexo IV.

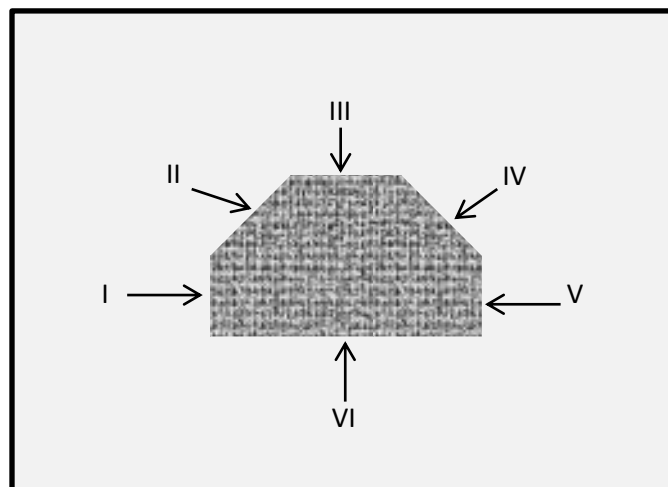


Figura 11: I y V bordes verticales. III y VI horizontales II y IV bordes diagonales.

3.2 APLICACIONES

En esta sección se generarán diferentes imágenes de textura, las cuales serán combinadas de a pares o en ternas de texturas. En cada par o terna, las texturas de la combinación serán yuxtapuestas siguiendo algún patrón de combinación (por ejemplo, combinación horizontal), para conformar así una imagen de textura mixta. Esta nueva textura será susceptible de ser segmentada, intentando establecer la línea de yuxtaposición de las texturas individuales que la integran, a partir de la metodología propuesta en la sección anterior. Se trabajó con imágenes de textura sintética de tamaño inicial 256x256. En cada ejemplo de aplicación, se intentó previamente obtener la segmentación utilizando el procedimiento con el umbral de Otsu, lo cual arrojó resultados deficientes, a diferencia de los obtenidos con el Método I, aquí propuesto.

3.2.1 Combinación vertical

En la figura 12 se muestra la combinación vertical de dos áreas de textura.




Figura 12: a) Imagen de textura I; b) Imagen de textura II; c) Imagen mixta obtenida a partir de la yuxtaposición vertical de las texturas I y II.

Se desea segmentar la imagen de textura mixta. Como primera instancia se aplicó sobre la imagen el método Otsu. El resultado se muestra en la figura 13.




Figura 13: Aplicación del método Otsu para la yuxtaposición vertical de dos imágenes de textura.

Notemos que para una mejor visualización de los resultados de la segmentación de Otsu, se usaron los colores rojo y amarillo, cada uno de los cuales estaría asociado a un tipo de textura en la imagen. El método Otsu confunde las texturas, no logrando la discriminación deseada.

Seguidamente se aplicó el método propuesto (Método I), eligiendo $m = n = 17$, $t = 1 = k$, y resultando $h = l = 240$. Las matrices de parámetros $A_{0,1}$ y $A_{1,0}$, ambas de dimensión 240×240 , contienen respectivamente las estimaciones mínimo cuadráticas de las primeras y segundas componentes de las estimaciones de los parámetros asociados a los modelos AR-2D de ajuste local a la imagen mixta. Estas matrices se pueden visualizar en la figura 14.




Figura14: a) Matriz de parámetros $A_{0,1}$; b) Matriz de parámetros $A_{1,0}$.

Se aplicó luego el método Otsu a las matrices de parámetros, obteniéndose como resultado las imágenes que se presentan en la figura 15.




Figura15: a) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$; b) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$.

Notemos que tanto en la figura 15 a) como en la 15 b) existen dos regiones bien definidas, separadas por un borde continuo. Clasificando estos puntos de borde respecto a ambas matrices de parámetros (según el método descrito en sección anterior), se obtendrá el borde en la imagen mixta. En la figura 16 se muestra en rojo los candidatos a borde respecto a la matriz de parámetros $A_{0,1}$ y en verde los de la matriz de parámetros $A_{1,0}$. La selección final del borde en cada fila de la imagen se llevó a cabo por el procedimiento **i**, de selección aleatoria, presentado más arriba.

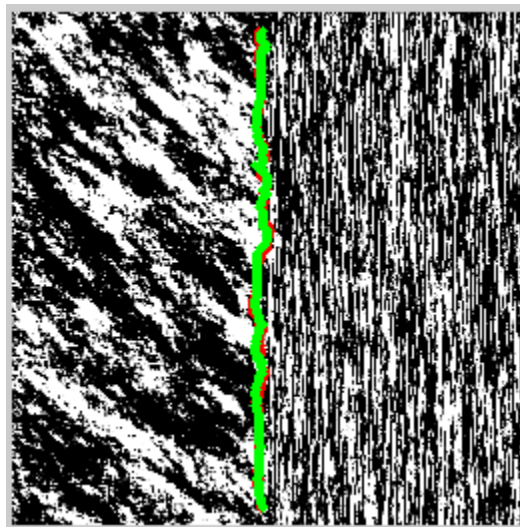


Figura 16: Marca de candidatos a borde respecto a ambas matrices de parámetros, en verde con respecto a $A_{1,0}$ y en rojo a $A_{0,1}$.

Una vez detectados los bordes en la imagen se procede a marcar como regiones homogéneas de textura a las comprendidas entre los bordes. En el caso aquí desarrollado, se detecta un solo borde vertical, por lo cual se considerará que la región a la derecha del borde es homogénea respecto a la característica textura, como así también la región a la izquierda. La segmentación lograda se muestra en la figura 17.



Figura 17: Segmentación de la imagen de la Figura 12, c), donde se distinguen dos áreas de texturas, diferenciadas a partir del Método I.

Nótese la presencia de sectores de píxeles sin segmentar en el margen superior e inferior de la figura 17. Esto se debe a que se escogió marcar como punto de borde al pixel central de la ventana. En el caso de la franja superior, los píxeles por arriba del pixel central quedan excluidos de la segmentación. Lo mismo sucede en la parte inferior, donde los píxeles por debajo del pixel central de cada ventana también quedaran excluidos. Este mismo problema se presenta en el margen derecho e izquierdo de la imagen, el cual se soluciona (para el caso de un solo borde vertical) en virtud de lo señalado en el párrafo anterior, previo a la Figura 17. Para facilitar la interpretación visual de las imágenes segmentadas se suprimirá estas franjas sin segmentar en todos los ejemplos de aplicación posteriores.

Con este procedimiento se distingue claramente las texturas yuxtapuestas en la imagen mixta, proporcionando una mejora a la segmentación por el método Otsu.

3.2.2 Combinación Horizontal

Veamos ahora el funcionamiento del Método I, en el caso de la yuxtaposición de dos texturas en formato horizontal. Con este objetivo se generó una imagen mixta compuesta por la combinación horizontal de dos imágenes de textura (Figura 18 a) y b)). El resultado puede verse en la Figura 18 c).




Figura 18: a) Primera imagen de textura; b) Segunda imagen de textura; c) Imagen mixta a partir de la combinación horizontal de a) y b).

Luego se aplicó el método de segmentación basado en el umbral de Otsu. En la figura 19 puede verse en rojo y amarillo la segmentación lograda por este método.




Figura 19: Aplicación del método Otsu para la yuxtaposición horizontal de dos imágenes de textura.

Nuevamente el Método de Otsu confunde las texturas, no logrando la discriminación deseada. Se procede entonces a aplicar el Método I. En la figura 20 se muestran las

imágenes ficticias correspondiente a las matrices de parámetros, como así también el resultado de aplicar el método de Otsu a estas imágenes.

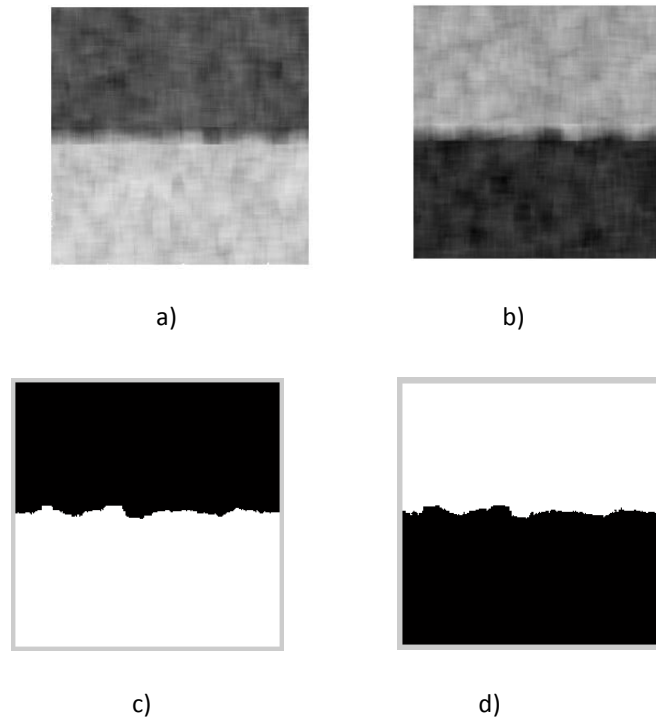


Figura 20: a) Matriz de parámetros $A_{0,1}$; b) Matriz de parámetros $A_{1,0}$; c) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$; d) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$.

Se señalaron en la imagen mixta los posibles puntos de borde detectados por el Método I, estableciendo por cada columna un único borde según un criterio de selección aleatorio definido para las columnas. El resultado de la segmentación se muestra en la figura 21.




Figura 21: a) Marca de candidatos a borde respecto a ambas matrices de parámetros, en verde con respecto a $A_{1,0}$ y en rojo a $A_{0,1}$. b) Dos áreas de texturas a partir de aplicar el método I.

El método propuesto ha proporcionado una buena segmentación de la imagen mixta.

3.2.3 Combinación diagonal

Para comprobar la aplicación del método I en relación a una combinación diagonal, se simula una imagen mixta en la cual se yuxtaponen dos texturas de tal manera, resultando la imagen representada en la figura 22.




Figura 22: a) Primera imagen de textura; b) Segunda imagen de textura; c) Imagen mixta a partir de la yuxtaposición diagonal de a) y b).

Con el objetivo de segmentar la imagen mixta diagonal, se procede a aplicar el Método I. Los resultados intermedios y el resultado final son presentados en la Figura 23.




Figura 23: a) Matriz de parámetros $A_{0,1}$; b) Matriz de parámetros $A_{1,0}$; c) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$; d) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$; e) Marca de candidatos borde; f) Resultado de segmentación de áreas de texturas.

Nuevamente en este caso el método propuesto realiza la segmentación deseada de la imagen de textura.

A continuación se desarrollan aplicaciones donde la imagen mixta a segmentar presenta mayor complejidad.

3.2.4 Franja vertical

Caso 1:

La imagen mixta contiene una región vertical central cuya textura difiere de la textura de un fondo sobre el que se ha solapado dicha región vertical (Ver Figura 24).





Figura 24: a) Imagen que define una textura vertical, central en la imagen mixta que se desea segmentar. b) Imagen de textura, fondo de la imagen mixta. c) Imagen mixta, a partir de la combinación de a) y b).

En la figura 25 se muestran los resultados obtenidos a partir de aplicar el Método I.






Figura 25: a) Matriz de parámetros $A_{0,1}$. b) Matriz de parámetros $A_{1,0}$. c) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$. d) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$. e) Segmentación producida por el Método I. Bordes hallados y regiones de textura separadas por dichos bordes.

En este caso, el método propuesto señala dos líneas de borde como líneas de cambio en la textura, distinguiéndose tres subregiones en la imagen mixta, las que han sido denominadas P_1, P_2 y P_3 (Figura 25 e)). De acuerdo con el procedimiento aplicado, es posible señalar que la textura de P_1 es diferente de la textura de P_2 y que la textura de P_2 es diferente de la textura de P_3 . Se debe ahora hacer la comparación entre la textura de P_1 y P_3 .

Inicialmente conviene analizar en forma visual las matrices de parámetros (Figura 26). El análisis visual de la matriz de parámetros $A_{0,1}$ indica diferencias en la textura entre Q_1 y

Q_2 y entre Q_2 y Q_3 , para el caso, donde Q_i ; $1 \leq i \leq 3$ indica la i -ésima subregión de la matriz de parámetros $A_{0,1}$, correspondiente a la subregión P_i de la imagen mixta.




Figura 26: Subregiones en las matrices de parámetros.

Puede observarse la similitud entre las texturas Q_1 y Q_3 , lo que permite suponer que son las mismas texturas. Un análisis similar puede hacerse para las R_i , $1 \leq i \leq 3$ subregiones de la matriz de parámetros $A_{1,0}$.

Para realizar la comparación entre las texturas P_1 y P_3 se procede a yuxtaponer estas subregiones, con el fin de tener una nueva imagen, la cual se intentará segmentar por método I. Para esta yuxtaposición será necesario elegir fragmentos dentro de las secciones que tengan el mismo tamaño y que sean lo más representativas posibles de cada subregión. En la figura 27 a) se observa en amarillo los borde detectados y en rosado las dos fragmentos a yuxtaponer, y en la figura 27 b) la nueva imagen a segmentar (yuxtapuesta).




Figura 27: a) Secciones a segmentar, b) yuxtaposición de fragmentos (nueva imagen a segmentar).

Se procede según lo descrito en sección 3.1 a calcular las matrices de parámetros. Estas imágenes ficticias se muestran en la figura 28.




Figura 28: a) Matriz de parámetros $A_{0,1}$ de la yuxtaposición de subregiones b) Matriz de parámetros $A_{1,0}$ de la yuxtaposición de subregiones.

Luego se le aplica a estas matrices de parámetros el método de segmentación de Otsu. El resultado puede verse en la figura 29.




Figura 29: a) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$; b) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$.

El resultado anterior muestra que el método de Otsu aplicado a las matrices de parámetros no proporciona un borde, por lo cual la imagen yuxtapuesta es homogénea en la textura. Se concluye entonces que P_1 y P_3 son las mismas texturas.

La segmentación de una imagen mixta, compuesta por un tramo de imagen sobre un fondo, donde las dos texturas se yuxtaponen de manera vertical, provocando una franja en el centro puede verse en la figura 30.



Figura 30: Resultado de segmentación de áreas de texturas, a partir del método I.

El método proporciona una segmentación exitosa de dos texturas que se yuxtaponen verticalmente en una franja sobre un fondo.

3.2.5 Franja diagonal

Caso 2:

La imagen mixta está compuesta por una franja diagonal cuya textura difiere de la textura de un fondo sobre el que se ha solapado dicha franja diagonal (figura 31 a)).

A ésta imagen mixta se le aplicó Método I de segmentación de imágenes de textura. Todo el procedimiento puede observarse en la figura 31.






Figura 31: a) Imagen mixta; b) Matriz de parámetros $A_{0,1}$; b) Matriz de parámetros $A_{1,0}$; c) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$; d) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$; e) Segmentación producida por el Método I. Bordes hallados y regiones de textura separadas por dichos bordes.


En este caso, se distinguen tres subregiones en la imagen mixta señaladas a partir de dos líneas de borde como líneas de cambio en la textura. Sean estas subregiones P_i , $1 \leq i \leq 3$, se procede de forma similar a lo desarrollado en el caso anterior. Los resultados pueden verse en la figura 32.




a)



b)




c)



d)



e)



f)

Figura 32: a) Secciones a segmentar, b) yuxtaposición de subregiones (nueva imagen a segmentar), c) Matriz de parámetros $A_{0,1}$ de la yuxtaposición de subregiones, d) Matriz de parámetros $A_{1,0}$ de la yuxtaposición de subregiones; e) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$, f) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$.

En este caso el método de Otsu aplicado a las matrices de parámetros no proporciona un borde, por lo cual la imagen mixta es homogénea en la textura. Se concluye entonces que P_1 y P_3 son las mismas texturas.

En la figura 33 se muestra el resultado de la segmentación de una imagen mixta.




Figura 33: Resultado de segmentación de áreas de texturas en combinación franja diagonal.

Según lo desarrollado hasta aquí, el método propuesto resulta eficaz para segmentar imágenes sintéticas de textura mixta, a partir de dos texturas. Es necesario entonces, ver cómo responde el método I para la combinación de tres texturas.

3.2.6 Tres texturas

Veamos ahora el funcionamiento del Método I, en el caso de tres texturas solapadas verticalmente. El resultando la imagen representada en la figura 34.





Figura 34: a) Primera imagen de textura; b) Segunda imagen de textura; c) tercera imagen de textura; d) Imagen mixta a partir de la combinación vertical de a), b) y c).

Se le aplicó el método I de segmentación a esta imagen mixta, los resultados se muestran en la figura 35.






Figura 35: a) Matriz de Parámetro $A_{0,1}$; b) Matriz de Parámetro $A_{1,0}$; c) Otsu aplicado a $A_{0,1}$; d) Otsu aplicado a $A_{1,0}$; e) Segmentación producida por el Método I. Bordes hallados y subregiones de textura separadas por dichos bordes.

La imagen segmentada está constituida por tres subregiones de textura que se deben clasificar (figura 35 e)). Nuevamente se puede asegurar que la textura P_1 es diferente de la textura P_2 y que la textura P_2 es diferente de la textura P_3 . Se procede a aplicar el mecanismo ya desarrollado para la clasificación de subregiones. El desarrollo completo puede observarse en la figura 36.

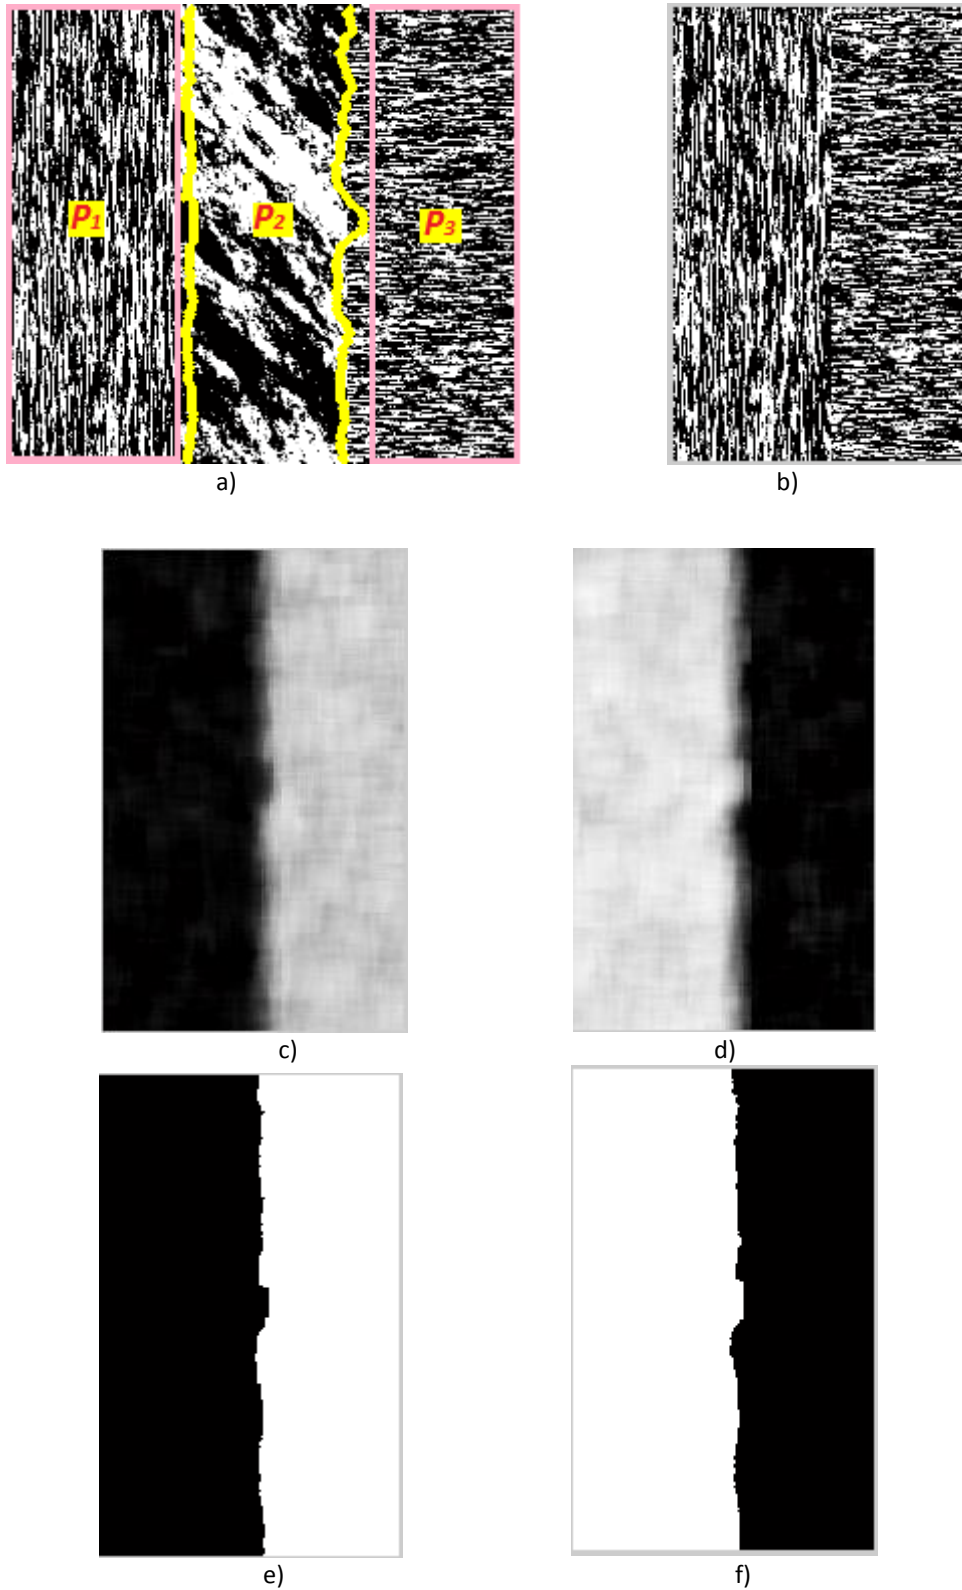


Figura 36: a) Secciones a segmentar, b) yuxtaposición de fragmentos (nueva imagen a segmentar), c) Matriz de parámetros $A_{0,1}$ de la yuxtaposición de fragmentos, d) Matriz de parámetros $A_{1,0}$ de la yuxtaposición de fragmentos; e) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{0,1}$, f) Resultado de Aplicar el método Otsu a la matriz de parámetro $A_{1,0}$.

Como el método Otsu distinguió dos texturas diferentes, se puede entonces concluir que la textura P_1 no es la misma que la textura P_3 , obteniéndose una segmentación diferente a los casos desarrollados a partir de dos texturas, como se observa en la figura 37.



Figura 37: Resultado de la segmentación de la imagen mixta de tres texturas por el método I.

Según los ejemplos de aplicación desarrollados se puede suponer que el método I de segmentación funciona correctamente en imágenes sintéticas de textura.

Notemos que a partir estas aplicaciones podemos asegurar que el método I proporciona una mejora en la segmentación de imágenes de textura donde el método del umbral de OTSU aplicado a la imagen mixta falla. Este es uno de los aportes de ésta tesis.

Capítulo 4

Como se explicó en el capítulo anterior, en esta tesis se proponen dos metodologías para la segmentación de imágenes de textura sintéticas. En este Capítulo presentaremos la segunda propuesta, que se basa en análisis de series de datos temporales generadas a partir de las matrices de parámetros definidas en el Capítulo 3, y al que llamaremos “Método II”. Como en el caso de la propuesta del Método I, la intención de la nueva propuesta está dirigida a lograr un algoritmo útil para la segmentación de imágenes de textura y como en el Método I, se ajusta localmente a la imagen a segmentar un modelo AR-2D con dos parámetros, obteniéndose dos matrices de parámetros, según lo desarrollado en la sección 3.1. Hasta aquí el Método I y el Método II, son idénticos

4.1 SEGMENTACIÓN BASADA EN SERIES TEMPORALES ORDENADAS

4.1.1 Introducción

Del análisis de imágenes sintéticas de textura mixta analizados en el capítulo 3 y de la consideración de que cada fila (o columna) de cada una de las matrices de parámetros de una imagen de textura constituye una secuencia de datos ordenados según la posición en la fila (o columna) de cada dato, y que esta información puede graficarse por filas (o columnas) como una serie de datos indexada, se plantea la posibilidad de segmentar texturas en base al análisis de series de datos temporales.

A modo de introducción se presentan algunas definiciones sobre series temporales necesarias para la descripción del método II.

Desde el punto de vista estadístico una serie de tiempo es una colección de variables aleatorias que están ordenadas según un conjunto de índice, que en general es un conjunto de tiempos. Según este conjunto de índices sea numerable o no, se dirá que es una serie de tiempo discreto o una serie de tiempo continuo. La notación usualmente empleada para series de tiempo discreto es $\{X_t: t \in T\}$ (en general $T = \mathbb{Z}$ o $T = \mathbb{N}$) donde

X_t es una variable aleatoria para todo t , mientras que para series de tiempo continuo se usa la notación $X(t): t \in T$ donde generalmente $T = \mathbb{R}$ (Leiva, 1995). En este trabajo se emplearan series de tiempo discreto con $T = \mathbb{N}$.

Una de las clasificaciones descriptiva de las series temporales se refiere a si es estacionaria o no. Una serie es estacionaria cuando es estable, es decir, cuando la media y la variabilidad son constantes a lo largo del tiempo. Esto se refleja gráficamente en que los valores de la serie tienden a oscilar alrededor de una media constante y la variabilidad con respecto a esa media también permanece constante en el tiempo (Marín, 2013).

4.1.2 Método II

Sean $A_{0,1}$ y $A_{1,0}$ las *matrices de parámetros* (estimados), presentadas en la sección 3.1. Es decir $A_{0,1}$ es la matriz de todas las primeras componentes de las $l \times h$ estimaciones de los vectores de parámetros y $A_{1,0}$ la de todas las segundas componentes. Más precisamente:

$$A_{0,1} = \begin{pmatrix} \hat{a}_{0,1}^{11} & \dots & \hat{a}_{0,1}^{1h} \\ \vdots & \ddots & \vdots \\ \hat{a}_{0,1}^{l1} & \dots & \hat{a}_{0,1}^{lh} \end{pmatrix} \text{ y } A_{1,0} = \begin{pmatrix} \hat{a}_{1,0}^{11} & \dots & \hat{a}_{1,0}^{1h} \\ \vdots & \ddots & \vdots \\ \hat{a}_{1,0}^{l1} & \dots & \hat{a}_{1,0}^{lh} \end{pmatrix}$$

Si se considera a la fila i -ésima de $A_{0,1}$ como una secuencia de datos ordenados según la posición en la fila de cada dato, ésta constituirá una serie de tiempo indexada a la posición de la columna. La series de tiempo discreto para esta i -ésima fila será

$$\{\hat{a}_{0,1}^{ij}: j \in \mathbb{N} \wedge 1 \leq j \leq h\}$$

Esta serie tendrá la particularidad de ser estacionarias en la sección de $A_{0,1}$ que representan una misma textura y mostrarán un salto en los bordes entre dos texturas.

De manera análoga se define a la serie de tiempo discreto correspondiente a la i -ésima fila de $A_{1,0}$, con las mismas características que la anterior:

$$\{\hat{a}_{1,0}^{ij}: j \in \mathbb{N} \wedge 1 \leq j \leq h\}$$

Es de suponer que, si estas dos series definidas muestran saltos en el borde entre dos texturas deben cruzarse. Y es precisamente en este cruce donde se encuentra el punto borde a establecer.

Sea $\hat{a}_{0,1}^{iz} \cong \hat{a}_{1,0}^{iz}$ la posición donde se cruzan las series temporales. Denominaremos a $\hat{a}_{0,1}^{iz}$ píxel de cruce de las series temporales correspondientes a las i -ésimas fila de $A_{0,1}$; entonces la subimagen W_{iz} (ventana de borde) será una región de la imagen C asociada a píxeles donde cambia la textura en C . Una vez identificada la ventana de borde W_{iz} , se clasificará como borde de C al píxel central de dicha ventana.

De no existir puntos de cruce entre las series se considerará que la fila es homogénea en la textura. De existir más de un punto de cruce se procederá como le expuesto en la sección 3.1.

Si se repite el procedimiento para cada fila de $A_{0,1}$ con su respectiva fila en $A_{1,0}$ se deben detectar bordes tanto verticales como diagonales.

Una análisis similar se desarrolla para las columnas de las matrices de parámetros, donde se considera a la j -ésima columna de $A_{0,1}$ como una secuencia de datos ordenados según la posición en la columna de cada dato, ésta constituirá una serie de tiempo indexada a la posición en la fila. La serie de tiempo discreto para esta j -ésima columna será

$$\{\hat{a}_{0,1}^{ij}: i \in \mathbb{N} \wedge 1 \leq i \leq l\}$$

Y la series de tiempo discreto para la j -ésima columna de $A_{1,0}$ es:

$$\{\hat{a}_{1,0}^{ij}: j \in \mathbb{N} \wedge 1 \leq j \leq l\}$$

Hallando el punto de cruce de estas dos series se detectarán bordes horizontales y diagonales. Es importante realizar el procedimiento tanto por filas como por columnas, si se aplica el método II sólo por filas la habilidad de detección de bordes se deteriora. El pseudocódigo del método puede verse en el anexo v.

A continuación se muestran los resultados que arrojó el Método II a diferentes situaciones prácticas.

4.2 APLICACIONES

4.2.1 Imagen Mixta con yuxtaposición vertical de dos texturas.

En primer lugar se generó una imagen sintética con dos áreas de textura diferente según el procedimiento descrito en la sección 3.2.1 y se calcularon sus matrices de parámetros, como en el Capítulo 3.




Figura 38: a) Imagen mixta de textura; b) Imagen de la matriz de parámetros $A_{0,1}$. c) Imagen de la matriz de parámetros $A_{1,0}$.

Al graficar una fila de la matriz de parámetros $A_{0,1}$, puede observarse una serie bien definida. A modo de ejemplo en la figura 39 se ilustra el caso para la fila 100 de $A_{0,1}$.




Figura 39: Gráfica de la fila 100 de la matriz de parámetros $A_{1,0}$.

Si se gráfica la serie correspondiente a la misma fila para la matriz $A_{1,0}$ (basada en la estimación del segundo parámetro) puede también observarse una serie bien definida. Resulta interesante observar que estas dos series de datos, correspondiente a la misma fila en ambas matrices de parámetros, se cruzan y que el punto de intersección se produce, en principio, para una única posición en la fila. En la figura 40 se muestra la gráfica de las dos series correspondientes a la fila 38 de ambas matrices de parámetros.




Figura 40: Gráfica de la fila 38 de ambas matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$.

Para este caso las series se cruzan en un único punto, y según lo expuesto en el método II, una manera de segmentar las texturas de la imagen mixta, consiste en definir la posición del cambio de textura, como aquella que se deriva de la posición correspondiente al cruce entre las series. Se procede entonces a buscar el cruce de estas series temporales en las matrices de parámetros y se marca en C (imagen a segmentar) como punto de borde al pixel central de la ventana que generó el valor del parámetro.

El procedimiento se aplica a cada la fila de las matrices de parámetros, para así marcas los puntos de borde en C . El resultado puede verse en la figura 41.




Figura 41: Línea de borde marcada desde el punto de cruce de las dos series temporales.

El borde marcado en la figura 41 divide a la imagen mixta en dos áreas de textura bien definidas.

Nótese que, si se grafican las respectivas columnas de las matrices de parámetros (figura 42), las series temporales no se cruzan. Por lo que es de suponer que no existe un borde horizontal.




Figura 42: Series temporales relativas a las columnas de las matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$.
a) Columna 34; b) Columna 120.

En la figura 43 se muestra el resultado de aplicar el método II a la imagen de textura mixta.



Figura 43: Dos áreas de textura segmentadas por el método II, combinación vertical.

Con el método II se distingue claramente las texturas yuxtapuestas en la imagen mixta. Nuevamente la presencia de sectores de píxeles sin segmentar en el margen superior e inferior se debe a que se escogió marcar como punto de borde al pixel central de la ventana. Para facilitar la interpretación visual de las imágenes segmentadas se suprimirá estas franjas sin segmentar en todos los ejemplos de aplicación posteriores.

4.2.2 Franja diagonal de dos texturas.

Se verá ahora la yuxtaposición de dos texturas, combinándolas en una franja diagonal, procedimiento descrito en la sección 3.2.5. (Figura 44)




Figura 44: Yuxtaposición de dos imágenes de textura en una franja diagonal.

A la imagen mixta obtenida se le calculan las matrices de parámetros. Con el objetivo de marcar el borde entre texturas, se busca el cruce tanto de las series temporales horizontales (filas de las matrices de parámetros), como también verticales (columnas de las matrices de parámetros). Finalmente se marca en la imagen mixta estos candidatos a borde. En la figura 45 se muestra este resultado y el cruce de las series correspondiente a una fila y a una columna en particular en ambas matrices de parámetros.




Figura 45: a) Gráfica de la fila 157 de ambas matrices de parámetros en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$; b) Gráfica de la columna 60 de ambas matrices de parámetros en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$; c) Líneas de borde marcadas por el método II.

El borde en la imagen mixta se calcula seleccionando aleatoriamente uno de los píxeles candidatos a borde, como se desarrolló en la sección 3.2.1. y se clasifican las partes constituyentes según lo expuesto en la sección 3.2.4. El resultado de la segmentación puede observarse en la figura 46.




Figura 46: Dos áreas de textura segmentadas por el método II, franja diagonal.

El resultado de la segmentación de la imagen de textura mixta es adecuado con el método II.

4.2.3 Combinación vertical de tres texturas.

Se genera una imagen mixta compuesta de tres áreas de textura, mediante el procedimiento descrito en la sección 3.2.6. Se aplica el método II de segmentación basado en series temporales. El resultado puede verse en la figura 47.




Figura 47: a) Gráfica de la fila 124 de ambas matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$; b) Líneas de borde marcadas desde el cruce de las series temporales. c) Resultado de la segmentación de tres texturas por el método II.

Nuevamente, en este caso, el método propuesto realiza la segmentación deseada de la imagen de textura mixta.

Prosiguiendo en la evaluación de diferentes aplicaciones del método II, se desarrolló una imagen resultante de combinaciones más complejas.

4.2.4 Cuatro texturas yuxtapuestas

Se genera una imagen mixta, compuesta por cuatro áreas de texturas yuxtapuestas (figura 48).





Figura 48: Combinación de cuatro texturas.

Se calculan en la imagen mixta, las matrices de parámetros y se marcan los candidatos a borde respecto al cruce de las series tanto horizontales como verticales. Todo el procedimiento puede verse en la figura 49.



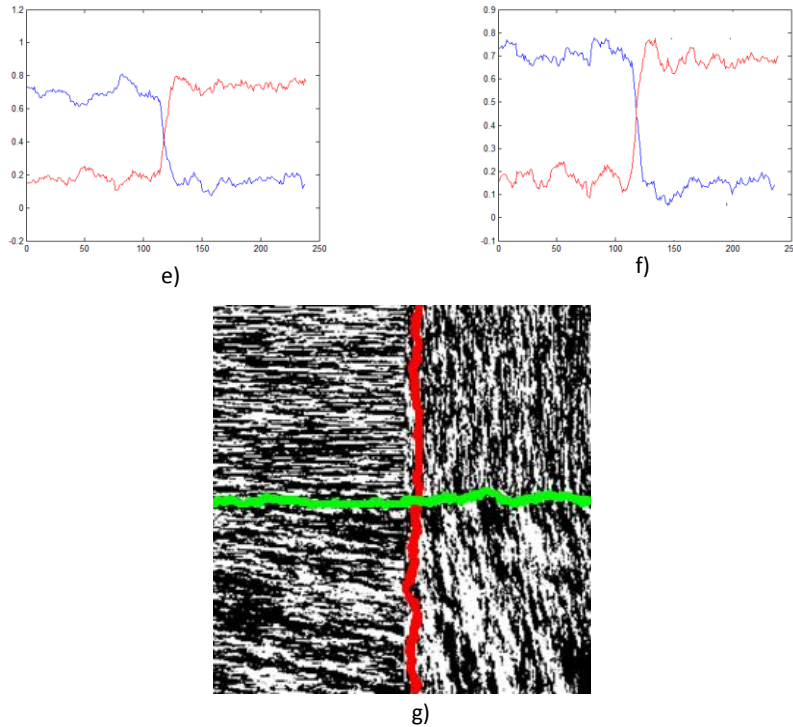


Figura 49: a) Matriz de parámetros $A_{0,1}$; b) Matriz de parámetros $A_{1,0}$; c) Gráfica de la fila 66 de ambas matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$; d) Gráfica de la fila 149 de ambas matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$; e) Gráfica de la columna 54 de ambas matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$; f) Gráfica de la columna 198 de ambas matrices de parámetros, en color azul la serie correspondiente a $A_{0,1}$ y en rojo la serie en $A_{1,0}$ y g) Líneas de borde marcadas desde el cruce de las series temporales. En verde, puntos de discontinuidad respecto a las columnas y en rojo respecto a las filas.

Nótese que en este caso hubo cuatro subregiones de textura segmentadas (figura50).




Figura 50: Subregiones distinguidas por el método II.

Se llamó P_1, P_2, P_3 y P_4 a las diferentes subregiones segmentadas (figura 50). Por tal segmentación, se sabe que la textura P_1 es diferente de las texturas P_2 y P_3 y que la

textura P_2 es diferente de las texturas P_1 y P_4 . Se debe hacer las comparaciones entre las texturas P_1 y P_4 y entre las texturas P_2 y P_3 , para ello se usó el procedimiento expuesto en la sección 3.2.4. El resultado de la segmentación puede verse en la figura 51.



Figura 51: Resultado de la segmentación de cuatro texturas a partir del método II.

A partir de las aplicaciones desarrolladas en este capítulo, podemos asegurar que el método II de segmentación, basado en series temporales, permite una correcta segmentación de imágenes sintéticas de textura.

CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS

En este trabajo se propusieron dos procedimientos matemático-estadísticos útiles para en segmentación de imágenes sintéticas de textura.

Se abordó el campo de segmentación de imágenes de textura correspondiente a la extracción de las características que generan las texturas a segmentar como también el problema de la discriminación entre estas características.

Durante el desarrollo de la tesis se ha trabajado con imágenes sintéticas de textura generadas a partir de modelo autorregresivos bidimensionales con dos parámetros, modelo AR-2D, el cual ha demostrado eficacia para reproducir localmente las características dinámicas de este tipo de imágenes.

En el capítulo 2 se presentó una breve síntesis de los aspectos teóricos relacionados con la definición y características del modelo AR-2D; asimismo se abordó la estimación mínimo cuadrática de los parámetros del modelo y su sensibilidad a la presencia de contaminación impulsiva sal y pimienta.

En el capítulo 3 se presentó la primera de las propuestas de la tesis, el Método I, el cual optimiza y complementa al método de Otsu, en base a la definición y procesamiento por Otsu de las llamadas “matrices de parámetros”. Se presentaron también diferentes ejemplos de aplicación de la propuesta. En base a los experimentos realizados, el Método I, logró segmentar diferentes imágenes mixtas de textura y resultó ser una mejora notable para los casos donde el método Otsu, aplicados directamente sobre la imagen, fracasa.

En el capítulo 4 se presentó una segunda propuesta para segmentar imágenes sintéticas de textura, llamada Método II. Este procedimiento que analiza por filas y columnas las matrices de parámetros. Tanto los datos por fila, como los datos por columna, se consideran series de datos indexadas respectivamente, por la posición en la

fila o columna. Cambios en el comportamiento de estas series, permiten detectar con notoriedad variaciones en la textura de la imagen. En base a las diferentes simulaciones realizada se puede asegurar que este procedimiento también logra la segmentación eficaz de imágenes sintéticas de textura.

Entre las posibles líneas de continuación de este trabajo, se pueden señalar las siguientes:

- Explorar la capacidad de las propuestas, Método I y Método II, para detectar bordes en imágenes reales provenientes de diferentes áreas de trabajo.
- Cuantificar la capacidad de los Métodos I y II para segmentar imágenes de textura a través de diferentes medidas de similaridad, desarrolladas a tal efecto.
- Comparar el método I y el Método II, tanto con respecto a la capacidad para lograr una segmentación óptima de texturas, como en relación al costo computacional.
- Profundizar este trabajo utilizando modelos autorregresivos bidimensionales con un parámetro y con tres parámetros.
- Analizar la capacidad de estas metodologías para segmentar imágenes de textura contaminadas a partir de diferentes esquemas de ruido.
- Estudiar diferentes estrategias para determinar el tamaño óptimo de ventana de ajuste local mediante modelos autorregresivos 2D.
- Optimizar los algoritmos desarrollados en Matlab que definen a los métodos I y II, mejorando su costo computacional.

Bibliografía

- Andrzej Materka y Michal Strzelecki. (1998). Texture Analysis Methods – A Review. *Technical University of Lodz, Institute of Electronics, COST B11 report*, 33.
- B.S. Manjunathi and W.Y. Ma. (1996). Texture Features for Browsing and Retrieval of Image Data. *IEEE TRANSACTIONS ON PATTERN AIVALYSIS AND MACHINE INTELLIGENCE*, 837-842.
- Brais Perez Prol y Javier Remeseiro Reguero. (14 de 09 de 2013). *Segmentación I*. Obtenido de http://carpente.es/archivos/fic/opt/va/Teoria/03%20-%20Segmentacion_I.pdf
- Bronzino, J. (2006). *Biomedical Engineering Fundamentals*. Taylor & Francis Group: United States of America .
- Castleman, K. R. (1996). *Digital image processing*. Englewood Cliffs, N.J.: Prentice Hall.
- Chuvieco, E. (1990). *FUNDAMENTOS DE TELEDETECCION ESPACIAL*. Madrid, España: Ediciones Rialp S. A.
- Federico Cristina, Sebastián H. Dapoto, Verónica Artola, Claudia Russo, Graciela Viegas. (2009). Detección de edificios en imágenes urbanas. *XV Congreso Argentino de Ciencias de la Computación*, 596-605.
- Fernández García, N. (11 de 12 de 2013). *Introducción a la Visión Artificial*. Obtenido de Visión Artificial Avanzada: <http://www.uco.es/users/ma1fegan/2011-2012/vision/Temas/ruido.pdf>
- Fernández López, C. (18 de 06 de 2014). *Desarrollo de métodos de procesamiento de imágenes Laríngeas en color para la detección del espacio glotal y de las cuerdas vocales*. Obtenido de Universidad Politécnica de Madrid: http://oa.upm.es/21319/1/PFC_CELIA_FERNANDEZ_LOPEZ.pdf
- Gil Rodríguez, J. L. (2008). *REPORTE TÉCNICO Reconocimiento de patrones*. Ciudad de La Habana.Cuba: CENATAV .
- Gil Rodríguez, J. L. (2011). *Evaluación de calidad en la segmentación de imágenes*. La Habana, Cuba.: CENATAV Serie Azul.
- González Martínez, V. (2013). *TÉCNICAS DE UMBRALIZACIÓN PARA LA DETECCIÓN DE ANOMALÍAS EN LA PARED AÓRTICA MEDIANTE OCT*. Cantabria, España: UNIVERSIDAD DE CANTABRIA.
- Gonzalez, Rafael & Woods, Richard . (2002). *Digital Image Processing*. New Jersey : Prentice-Hall, Inc.
- Haindl, M. (1991). Texture synthesis. *CWI Quarterly*, 305–331.

- Jesus Martínez-Gomez, J. G.-V. (2009). Uso de algoritmos genéticos para detección de objetos en tiempo real. *X WORKSHOP DE AGENTES FISICOS*, 87-94.
- Juan S. Botero Valencia y A. Restrepo Martínez. (2010). ANÁLISIS DE TEXTURA EN PANES USANDO LA MATRIZ DE COOCURRENCIA. *Revista Politécnica ISSN 1900-2351*, 74-80.
- Leiva, R. (1995). *Introducción al Análisis de las Series de Tiempo*. Mendoza: Facultad de Ciencias Económicas de la Universidad Nacional de Cuyo.
- Marín, J. (12 de 8 de 2013). *Series Temporales*. Obtenido de halweb.uc3m.es:
<http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/EDescrip/tema7.pdf>
- Oe, S. (1993). Texture Segmentation Method by Using Two-Dimensional Ar Model and Kullback Information. *Pattern Recognition*, 237-244.
- Ojeda, S. y Britos, G. (2013). A New Algorithm to Represent Texture Images. *International Journal of Advanced Computer Science and Applications*, 106-111.
- Ojeda, S., Vallejos, R., Bustos, O. (2010). A New Image Segmentation Algorithm with Applications to Image Inpainting. *Computational Statistics and Data Analysis*, 2082-2093.
- Otsu, N. (1979). A threshold selection method from grey level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 62-66.
- Pérez, J. M. (2009). *Procesamiento de Imágenes*. Recuperado el 22 de 06 de 2012, de
<http://www.lcc.uma.es/~munozp/>
- Ping-Sung Liao, Tse-Sheng Chen and Pau-Choo Chung. (2001). A Fast Algorithm for Multilevel Thresholding. *Journal of Information Science and Engineering* 17, 713-727.
- Proakis, J. y Manolakis, D. (1999). *Tratamiento Digital de Señales*. España: Prentice Hall.
- Sali, E. y Wolfson, H. (1992). Texture classification in aerial photographs and satellite data. *Internat. Jour. of Remote*, 13:18.
- Simó, D. S. (2012). *Diseño de un interfaz hombre máquina utilizando el entorno MATLAB para la detección y eliminación de ruido impulsivo en imágenes*. GANDIA: UNIVERSIDAD POLITECNICA DE VALENCIA.
- Visión-Artificial. (Octubre de 2005). *Segmentación por Umbralización-Método de Otsu*. Obtenido de Universidad Nacional de Quilmes – Ing. en Automatización y Control Industrial: 2005. Disponible en: <http://iaci.unq.edu.ar/materias/vision/apuntes.htm>
- Whittle, P. (1954). On stationary processes on the plane. *Biometrika* 41, 434-449.
- Xie, X. (2008). A Review of Recent Advances in Surface Defect Detection using Texture analysis Techniques. *Electronic Letters on Computer Vision and Image Analysis*, 1-22.

ANEXO I

Pseudocódigo del Método Otsu

Paso 1: Computar el histograma normalizado de la imagen.

Sea $f(x, y)$ una imagen de $M \times N$ píxeles;

Niveles de gris de la imagen = $\{1, 2, \dots, L\}$;

n_i número de píxeles con nivel de intensidad i ;

probabilidad de que ocurra el nivel de intensidad i $p_i = \frac{n_i}{M \times N}$.

Paso 2: Calcular las sumas acumuladas

$$\omega_1(k) = \sum_{i=1}^k p_i \quad k = 1, 2, \dots, L$$

Si se fija un valor umbral t en el nivel de intensidad k ($t = k$), los píxeles de la imagen se dividen en dos clases:

C_1 = píxeles con niveles de gris $[1, \dots, t]$

C_2 = píxeles con niveles de gris $[t + 1, \dots, L]$.

Entonces, $\omega_1(k)$ indica la probabilidad de que un píxel pertenezca a la clase C_1 .

Paso 3: Calcular las medias acumulativas $\mu(k), k = 1, 2, \dots, L$

$$\mu(k) = \sum_{i=1}^k i \cdot p_i$$

Paso 4: Calcular la media global μ_T de toda la imagen.

$$\mu_T = \sum_{i=1}^L i \cdot p_i$$

Paso 5: Calcular la varianza entre clases

$$\sigma_B^2(t) = \omega_1(t) \cdot (\mu_1 - \mu_T)^2 + \omega_2(t) \cdot (\mu_2 - \mu_T)^2$$

Este valor mide la dispersión entre los valores de intensidad de las dos clases C_1 y C_2 definidas al tomar como valor umbral el valor de intensidad t .

Paso 6: Maximizar la varianza anterior

$$t^* = \max\{\sigma_b^2(t)\} \quad 1 \leq t \leq L$$

Este paso persigue el objetivo inicial, dispersar lo máximo posible los niveles de intensidad de las dos clases. Si el máximo no es único, definir t^* como la media de todos los máximos posibles.

ANEXO II

Pseudocódigo para general imagen sintética de textura

Paso 1: Decidir el tamaño de la imagen a generar.

Seleccionar $M, N \in \mathbb{N}$

Generar una matriz de orden $M \times N$ que contenga valores aleatorios extraídos de una distribución normal estándar, a la que llamamos $\eta = (n_{ij})$

Paso 2: Modelar la imagen a partir de un modelo autorregresivo bidimensional (AR-2D)

Escoger el orden del modelo AR-2D que se va a usar, es decir los valor de $P, Q \in \mathbb{Z}^+$, de tal manera que se pueda elegir los parámetros del modelo.

Seleccionar los parámetros del modelo AR-2D, llamados a_{pq} , teniendo en cuenta que

- i. $D = \{(p, q) / 0 \leq p \leq P, 0 \leq q \leq Q\}$
- ii. $a_{00} = 0$
- iii. Para que el modelo sea causal y estacionario, se requiere que

$$\sum_{(p,q) \in D} |a_{pq}| \leq 1$$

Paso 3: Reproducir localmente las características dinámicas de una imagen de textura aplicando el modelos AR-2D.

Se calcula una nueva matriz $X = (x_{ij})$, donde el valor de elemento de la posición (i, j) de la imagen son deducidos dándole el peso a_{pq} a los vecinos correspondientes.

$$x_{ij} = \sum_{(p,q) \in D} \sum a_{pq} x_{i-p, j-q} + n_{ij},$$

Paso 4: Restar la media global μ de la matriz X .

Se calcula la media de los valores de la matriz X

$$\mu = \frac{1}{M \times N} \sum_{j=1}^N \sum_{i=1}^M x_{ij}$$

Paso 5: General imagen sintética de textura

Se genera la imagen de textura $T = (t_{ij})$, de tal forma que $t_{ij} = x_{ij} - \mu$

ANEXO III

Pseudocódigo para ajustar el modelo AR-2D con dos parámetros a una imagen de textura.

Paso 1: Elegir la imagen a la que se le quiere ajustar el modelo.

Seleccionar la imagen llamándola X

Calcular el tamaño de la matriz X

$$[n, m] = \text{tamaño}(X)$$

Paso 2: Elegir el orden del modelo autorregresivo bidimensional (AR-2D) a ajustar

Se decide $P = Q = 1$, con lo que el modelo es

$$x_{i,j} = a_{1,0}x_{i-1,j} + a_{0,1}x_{i,j-1} + e_{i,j}$$

Paso 3: Estimar los parámetros del modelo al que se ajusta la imagen

Calcular los valores acumulados

$$A = x_{i,j}x_{i-1,j}; \quad B = (x_{i-1,j})^2; \quad C = x_{i,j-1}x_{i-1,j}; \quad D = x_{i,j}x_{i,j-1} \quad \text{y} \quad E = (x_{i,j-1})^2,$$

Se resuelve el sistema de ecuaciones

$$\begin{cases} A = a_{1,0}B + a_{0,1}C \\ D = a_{1,0}C + a_{0,1}E \end{cases}$$

con lo que se obtendrá el vector de parámetros $(a_{1,0}; a_{0,1})$ que minimizan el error de predicción.

ANEXO IV

Pseudocódigo de segmentación de una imagen de textura mixta

METODO I

Paso 1: Elegir la imagen a la que se le quiere segmentar.

Seleccionar la imagen llamándola X

Calcular el tamaño de la matriz X

$$[N, M] = \text{tamaño}(X)$$

Paso 2: Elegir el tamaño de ventana que se va deslizar por la imagen original.

La ventana debe tener como medida $m \times n$, con $1 < m < M$ y $1 < n < N$

Paso 3: Estima el vector de parámetros $\hat{v}_{i1} = (\hat{a}_{0,1}^{i1}; \hat{a}_{1,0}^{i1})$ que ajustan el modelo AR-2D a la ventana definida en paso 2.

Paso 5: Escoger la distancia t a la que se trasladará ventana, con $t \leq N - n$.

Paso 6: Trasladar la ventana t lugares a la derecha y se estiman el parámetros que ajustan modelo AR-2D a esta ventana adyacente.

Paso 7: Repetir h veces el paso 6, con $h = \frac{N-(n-t)}{t}$ entero.

Paso 8: Elegir la distancia k a la que se desplazará la ventana hacia abajo, con $k \leq M - m$.

Paso 9: Trasladar la ventana k lugares a la abajo y se estiman el parámetros que ajustan modelo AR-2D a esta ventana.

Paso 10: Repetir los pasos 6 y 7.

Paso 11: Repetir l veces los pasos 9 y 10, con $l = \frac{M-(m-k)}{k}$ entero.

Paso 12: Generar las dos matrices parámetros. Donde $A_{0,1}$ la matriz que contiene a todas las primeras componentes y $A_{1,0}$ la matriz que contiene a todas las segundas componentes de los $l \times h$ vectores de parámetros.

$$A_{0,1} = (\hat{a}_{0,1}^{ij}) \text{ y } A_{1,0} = (\hat{a}_{1,0}^{ij})$$

Paso 13: segmentar la Matriz de parámetros $A_{0,1}$ a través del método Otsu.

Paso 14: de lo obtenido en el paso 13 se busca la posición donde cambia la textura y desde allí volver a la imagen original y marcar el valor central de la ventana que produjo ese valor de discontinuidad.

Paso 15: del resultado de 14 buscar una fila donde se halla resaltado los puntos de discontinuidad y:

- si el punto es único marcarlo como borde en X ,
- sino ordenar los puntos de discontinuidad por la posición en la fila y agruparlos de tal forma que cada grupo esté compuesto por candidatos cuya distancia espacial sea igual o inferior a $m + 1$ píxeles. Para cada grupo, seleccionar aleatoriamente uno de los píxeles entre todos los del grupo, y márcalo como borde en X .

ANEXO V

Pseudocódigo de segmentación de una imagen de textura mixta

METODO II

Paso 1: Elegir la imagen a la que se le quiere segmentar.

Seleccionar la imagen llamándola X

Calcular el tamaño de la matriz X

$$[N, M] = \text{tamaño}(X)$$

Paso 2: Elegir el tamaño de ventana que se va deslizar por la imagen original.

La ventana debe tener como medida $m \times n$, con $1 < m < M$ y $1 < n < N$

Paso 3: Estima el vector de parámetros $\hat{v}_{i1} = (\hat{a}_{0,1}^{i1}; \hat{a}_{1,0}^{i1})$ que ajustan el modelo AR-2D a la ventana definida en paso 2.

Paso 5: Escoger la distancia t a la que se trasladará ventana, con $t \leq N - n$.

Paso 6: Trasladar la ventana t lugares a la derecha y se estiman el parámetros que ajustan modelo AR-2D a esta ventana adyacente.

Paso 7: Repetir h veces el paso 6, con $h = \frac{N-(n-t)}{t}$ entero.

Paso 8: Elegir la distancia k a la que se desplazará la ventana hacia abajo, con $k \leq M - m$.

Paso 9: Trasladar la ventana k lugares a la abajo y se estiman el parámetros que ajustan modelo AR-2D a esta ventana.

Paso 10: Repetir los pasos 6 y 7.

Paso 11: Repetir l veces los pasos 9 y 10, con $l = \frac{M-(m-k)}{k}$ entero.

Paso 12: Generar las dos matrices parámetros. Donde $A_{0,1}$ la matriz que contiene a todas las primeras componentes y $A_{1,0}$ la matriz que contiene a todas las segundas componentes de los $l \times h$ vectores de parámetros.

$$A_{0,1} = (\hat{a}_{0,1}^{ij}) \text{ y } A_{1,0} = (\hat{a}_{1,0}^{ij})$$

Paso 13: considerar a la fila 1 de $A_{0,1}$ como una serie de datos indexada a la posición en la fila, considerar a la fila 1 de $A_{1,0}$ como una serie de datos indexada a la posición en la fila, buscar el punto de cruce de estas dos series.

Paso 14: de lo obtenido en el paso 13 se busca la posición en $A_{0,1}$ donde se produce el cruce y marcar en X el valor central de la ventana que produjo ese valor.

Paso 15: repetir los pasos 13 y 14 para cada fila de las matrices de parámetros.

Paso 16: del resultado de 15 buscar una fila donde se halla resaltado los puntos de cruce y:

- si el punto es único marcarlo como candidato borde en X ,
- sino ordenar los puntos de cruce por la posición en la fila y agruparlos de tal forma que cada grupo esté compuesto por candidatos cuya distancia espacial sea igual o inferior a $m + 1$ píxeles. Para cada grupo, seleccionar aleatoriamente uno de los píxeles entre todos los del grupo, y márcalo como candidato borde en X .

Paso 17: considerar a la columna 1 de $A_{0,1}$ como una serie de datos indexada a la posición en la columna, considerar a la columna 1 de $A_{1,0}$ como una serie de datos indexada a la posición en la columna, buscar el punto de cruce de estas dos series.

Paso 18: repetir los pasos 14, 15 y 16 para cada columna de las matrices de parámetros.

Paso 19: buscar una fila donde se halla resaltado los puntos de cruce y:

- si el punto es único marcarlo como borde en X ,
- sino ordenar los puntos de cruce por la posición en la fila y agruparlos de tal forma que cada grupo esté compuesto por candidatos cuya distancia espacial sea igual o inferior a $m + 1$ píxeles. Para cada grupo, seleccionar aleatoriamente uno de los píxeles entre todos los del grupo, y márcalo como borde en X .