

UNIVERSIDAD NACIONAL DE INGENIERÍA
FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA



TESIS:

“ESTIMACIÓN DE LA DINÁMICA DE SUELOS UTILIZANDO ANÁLISIS ESTOCÁSTICO DE SEÑALES DE RADAR DE APERTURA SINTÉTICA EN BANDA X”

PARA OBTENER EL GRADO ACADÉMICO DE MAESTRO EN CIENCIAS EN INGENIERÍA ELECTRÓNICA CON MENCIÓN EN PROCESAMIENTO DIGITAL DE SEÑALES E IMÁGENES

ELABORADO POR:

DAVID RONALD ATENCIA MONDRAGÓN

ASESOR:

DR. SAMUEL GUSTAVO HUAMÁN BUSTAMANTE

COASESOR:

DR. HUGO HERNANDEZ FIGUEROA

LIMA- PERÚ
2019

AGRADECIMIENTOS

En primer lugar, deseo agradecer al convenio MINEDU-FONDECYT por el financiamiento íntegro de mis estudios de maestría. La oportunidad otorgada es, sin duda, una oportunidad increíble para mi desarrollo profesional.

Agradezco también al INICTEL-UNI, por brindarme la infraestructura necesaria para poder finalizar el desarrollo del presente trabajo de tesis. Agradezco también a las coordinaciones I y II de la dirección de investigación y desarrollo tecnológico que me brindaron la asesoría técnica pertinente cuando la necesité. Agradezco a mi asesor de tesis quien siempre buscó la excelencia en mi investigación.

Este trabajo de tesis tampoco hubiera sido posible de realizar sin la cooperación de la UNICAMP y BRADAR, quienes me brindaron la base teórica y la base de datos utilizada en esta investigación. Quiero hacer una mención especial de agradecimiento al ingeniero João Moreira, quien fue un excelente profesor para mí y que además me brindó la confianza que necesitaba.

Finalmente, quiero agradecer a mi familia por confiar en mí. Gracias por cada consejo, sus palabras me llenaron de fuerzas para no detenerme.

DEDICATORIA

Dedico este trabajo a mis padres, por el gran apoyo que me brindaron a lo largo de mi desarrollo profesional. Por la confianza depositada en mí y los ánimos que me otorgaron, los cuales fueron indispensables para el desarrollo de esta tesis.

ÍNDICE

AGRADECIMIENTOS	2
DEDICATORIA.....	3
ÍNDICE.....	4
LISTA DE FIGURAS	8
LISTA DE TABLAS.....	11
LISTA DE VARIABLES MATEMÁTICAS	12
RESUMEN	17
INTRODUCCIÓN	18
1. CAPITULO I.....	20
1.1. Antecedentes.....	20
1.1.1. Situación problemática	22
1.1.2. Formulación del problema	24
1.1.3. Justificación e importancia de la investigación.....	25
1.1.4. Objetivos	25
1.1.5. Objetivo general	25
1.1.6. Objetivos específicos.....	25
1.1.7. Hipótesis.....	26
1.1.8. Hipótesis general.....	26
1.1.9. Hipótesis específicas	26
1.1.10. Variables e indicadores.....	26
1.1.11. Del objetivo general	26
1.1.12. De los objetivos específicos	26
1.2. Unidad de análisis	28
1.2.1. Ubicación.....	28
1.2.2. Toma de datos.....	28
CAPITULO II	30
2. MARCO TEÓRICO Y CONCEPTUAL.....	30

2.1.	Sistema de radar	30
2.1.1.	Tipos de radar según señal emitida	30
2.1.2.	Configuraciones básicas de radar.....	30
2.1.3.	Imágenes de radar	30
2.1.4.	Resolución.....	31
2.1.5.	Azimut y rango.....	31
2.2.	Radar de apertura sintética.....	32
2.2.1.	Escaneo de SAR	36
2.2.2.	Filtro coincidente	37
2.2.3.	Señal CHIRP	37
2.2.4.	Enfoque de imágenes de radar.....	38
2.2.5.	Compresión de pulso.....	38
2.2.6.	Compresión en azimut.....	40
2.3.	Filtros espaciales.....	42
2.4.	Regresión lineal.....	43
2.5.	Análisis de discriminación lineal	44
2.6.	Red neuronal artificial.....	47
2.7.	Reconocimiento de patrones	50
2.8.	Coherencia	51
2.9.	Teorema del límite central	51
2.10.	Teledetección	52
2.11.	Detección de movimiento en radares SAR	53
2.12.	Generación de stack de datos	55
2.13.	Deslizamientos	55
CAPITULO III		58
3.	METODOLOGÍA.....	58
3.1.	Tipo y nivel de investigación	58
3.2.	Diagrama de bloques del desarrollo del trabajo de tesis.....	58
3.3.	Periodo de análisis	61

3.4.	Fuentes de información e instrumentos utilizados	64
3.4.1.	Radar SENTIR-GEO.....	64
3.4.2.	Datos pluviométricos de INMET.....	65
3.4.3.	Técnica de Recolección de Datos.....	66
3.5.	Desarrollo del trabajo de tesis	66
3.5.1.	Pre procesamiento.....	69
3.5.1.1.	Filtraje en la frecuencia	70
3.5.1.2.	Composición de una vuelta de radar.....	70
3.5.2.	Clasificación de calidad de señal.....	75
3.5.3.	Calidad de la señal, movimientos sintéticos y descriptores.....	75
3.5.3.1.	Promedio de derivadas temporales.....	78
3.5.3.2.	Desviación estándar de la trama en el tiempo.....	79
3.5.3.3.	Rango dinámico de la trama en el tiempo	79
3.5.3.4.	Correlación espacial en azimut de las tramas en el tiempo.....	80
3.5.3.5.	Correlación espacial en rango de las tramas en el tiempo	81
3.5.3.6.	Movimiento detectado	82
3.5.3.7.	Diferenciales de la matriz de movimientos detectados	83
3.5.3.8.	Movimientos suavizados	84
3.5.4.	Diagrama del método para el cálculo de movimiento efectivo.....	85
3.5.5.	Cálculo de movimiento acumulado	85
3.5.5.1.	Media simple en el tiempo.....	86
3.5.5.2.	Ventana espacio temporal.....	86
3.5.5.3.	Estimación por mínimos cuadrados ponderados.....	87
3.5.6.	Clasificación de tramas de señal utilizando los descriptores y una red neuronal	89
3.5.7.	Cálculo de velocidad y aceleración de los movimientos geodinámicos..	90
CAPITULO IV.....		91
4.	PRUEBAS Y RESULTADOS	91
4.1.	Selección del mejor estimador de movimientos	91

4.2.	Elección del mejor tiempo de integración.....	97
4.3.	Análisis de descriptores de calidad.....	98
4.4.	Arquitectura y desempeño de la red neuronal artificial.....	101
4.5.	Validación con señal real.....	104
4.6.	Movimientos acumulados de la zona en análisis y correlación con datos pluviométricos.....	107
4.6.1.	Contrastación de la hipótesis general.....	112
4.6.2.	Contrastación de las hipótesis específicas.....	113
	CONCLUSIONES.....	114
	RECOMENDACIONES.....	116
	REFERENCIAS BIBLIOGRÁFICAS.....	117

LISTA DE FIGURAS

Figura 1.1. Histograma de huaycos y deslizamientos en Perú.	22
Figura 2.1. Geometría de la adquisición de datos para un SAR rotatorio	32
Figura 2.2. Resolución de <i>cross-range</i> de un radar (a) Ambigüedad en la detección de dos objetos (b) No ambigüedad en la detección de objetos.	33
Figura 2.3. Movimiento del radar para generar un arreglo de radares sintético.	34
Figura 2.4. Repetición de información acerca de un objetivo debido al movimiento del radar.	35
Figura 2.5. Radar de apertura sintética con trayectoria de tipo arco.	36
Figura 2.6. Señal CHIRP en el tiempo (parte real).	38
Figura 2.7. Espectro de la señal.	38
Figura 2.8. Señal CHIRP comprimida mediante la técnica del filtro de coincidencia.	40
Figura 2.9. Histórico de fase ideal y máscara para comprimir.	41
Figura 2.10 Compresión en azimut	41
Figura 2.11. Filtro espacial.	42
Figura 2.12 Máscara y porción de imagen a ser filtrada.	43
Figura 2.13. Algoritmo LDA usando el mínimo auto valor.	47
Figura 2.14. Algoritmo LDA usando el máximo auto valor.	47
Figura 2.15. Diagrama de una red neuronal artificial básica.	48
Figura 2.16. Fases medidas por el radar para un punto en específico y su comportamiento a través del tiempo (a) Sin movimiento de objeto y sin ruido (b) Sin movimiento del objeto y con ruido (c) Señal ruidosa correspondiente al movimiento de un objetivo.	54
Figura 2.17. Stack de datos.	55
Figura 3.1. Diagrama de bloques del desarrollo de la investigación.	60
Figura 3.2. Vista superior de la zona de alcance del radar.	62
Figura 3.3. Vista directa del radar hacia la pendiente.	62
Figura 3.4. Disposición geométrica de las antenas del radar y del objetivo.	64
Figura 3.5. Precipitaciones en los días de adquisición de señal.	66
Figura 3.6 Señal con problemas de fase doblada	67
Figura 3.7 Histogramas de fase de las regiones A, B, C y D (a) 50 muestras en el tiempo (b) 100 muestras en el tiempo (c) 250 muestras en el tiempo (d) 500 muestras en el tiempo (e) 1000 muestras en el tiempo.	69

Figura 3.8. Datos del stack utilizados para la generación de los histogramas de fase.	69
Figura 3.9. Matriz de datos correspondiente a un segundo de escaneo (a) Con <i>zero-padding</i> (b) Sin <i>zero-padding</i> .	71
Figura 3.10 Composición de matriz de una vuelta entera (a) Matriz sin <i>zero-padding</i> correspondiente a un segundo de adquisición (b) 50% de datos centrales de un segundo de adquisición (c) Colección de 4 adquisiciones no redundantes que corresponden a una vuelta entera de radar.	72
Figura 3.11. Composición de una vuelta de radar.	74
Figura 3.12. Formación de un <i>stack</i> .	76
Figura 3.13. Tramas sintéticas (a) Trama con baja SNR y movimiento alejándose al radar (b) Trama con buena SNR y saltos de fase con movimiento en dirección al radar.	77
Figura 3.14. Movimientos sintéticos en forma matricial para cada <i>Stack</i> . (a) Movimientos con baja correlación espacialmente (b) Movimientos con alta correlación espacial.	78
Figura 3.15. Información del stack utilizada para cálculo del primer descriptor.	78
Figura 3.16. Información del stack utilizada por el segundo descriptor.	79
Figura 3.17. Información del stack utilizada por el tercer descriptor.	80
Figura 3.18. Información del stack utilizada por el cuarto descriptor.	81
Figura 3.19. Información del stack utilizada por el quinto descriptor.	82
Figura 3.20. Información de la matriz de movimientos utilizada por el sexto descriptor.	83
Figura 3.21. Información de la matriz de movimientos utilizada para el cálculo del séptimo y octavo descriptor. (a) Coloreado en rojo el pixel de interés para el séptimo descriptor (b) Coloreado en rojo el pixel de interés para el octavo descripto.	84
Figura 3.22. Información de la matriz de movimientos utilizada para el cálculo del noveno descriptor.	85
Figura 3.23. Diagrama de bloques del método propuesto.	85
Figura 3.24. Método para la elección del mejor estimador de movimiento.	86
Figura 3.25. Método de cálculo de descriptores, cálculo de movimientos y clasificación de calidad de señal.	90
Figura 4.1. Secuencia de pasos para la comparación del desempeño de estimadores.	92
Figura 4.2. Desempeño de los estimadores. (a) Movimientos ideales sintéticos (b) Movimientos hallados por MS (c) Movimientos hallados por XY-T (d) Movimientos hallados por WLS.	96

Figura 4.3. Errores porcentuales del estimador WLS para tramas de diferentes duraciones de tiempo.	97
Figura 4.4. Tiempo de procesamiento para el estimador WLS para tramas de diferentes duraciones de tiempo.	98
Figura 4.5. Función de densidad de probabilidad de errores según el movimiento.	99
Figura 4.6. Desempeño del algoritmo LDA (a) LDA para descriptores antes del cálculo de movimiento (b) LDA para descriptores después del cálculo de movimiento.	101
Figura 4.7. Movimientos a detectar por el estimador WLS (a) <i>Stack</i> con alta correlación espacial. (b) <i>Stack</i> con baja correlación espacial.	102
Figura 4.8. Valores de <i>EWLSM</i> agrupados en matrices (a) Valores <i>EWLSM</i> para un stack con alta correlación espacial (b) Valores <i>EWLSM</i> para un stack con baja correlación espacial.	102
Figura 4.9. Arquitectura de la red neuronal utilizada para la clasificación de calidad de tramas de señal.	103
Figura 4.10. Matrices de confusión con el desempeño de las redes neuronales de reconocimiento de patrones (a) Capa oculta 5 neuronas (b) Capa oculta 10 neuronas (c) Capa oculta 15 neuronas (d) Capa oculta 20 neuronas (e) Capa oculta 25 neuronas (f) Capa oculta 30 neuronas.	104
Figura 4.11. Reflector o <i>corner</i> utilizado para la validación de la metodología.	105
Figura 4.12. Tendencia de movimientos del <i>corner</i> reflector.	105
Figura 4.13. Detalle de las posiciones del reflector a través del experimento de validación.	106
Figura 4.14. Movimientos, velocidad y aceleración de la superficie correspondiente a la “zona en análisis” para la serie expXerem_20160215.	107
Figura 4.15. Movimientos, velocidad y aceleración de la superficie correspondiente a la “zona en análisis” para la serie expXerem_20160216.	108
Figura 4.16. Movimientos, velocidad y aceleración de la superficie correspondiente a la “zona en análisis” para la serie expXerem_20160219.	109
Figura 4.17. Muro dañado por los movimientos ocurrido en la “zona en análisis”.	110
Figura 4.18. Movimientos acumulados para un 1 km de alcance para la serie expXerem_20160215.	111
Figura 4.19. Movimientos acumulados para un 1 km de alcance para la serie expXerem_20160216.	111
Figura 4.20. Movimientos acumulados para un 1 km de alcance para la serie expXerem_20160219.	112

LISTA DE TABLAS

Tabla 1.1 Susceptibilidad de pobladores, poblados y viviendas en Perú por deslizamientos.....	23
Tabla 1.2. Variables e Indicadores por Objetivo Específico.....	28
Tabla 1.3 Clasificación de lluvias en el periodo de toma de datos.....	29
Tabla 2.1. Clasificación de suelos.....	56
Tabla 2.2. Textura de suelo.....	56
Tabla 3.1 Cronograma de adquisición de la serie expXerem_20151209.....	63
Tabla 3.2. Resumen de especificaciones del radar.....	65
Tabla 3.3. Característica de cada <i>Stack</i>	76
Tabla 3.4. Descriptores utilizados para la clasificación de la calidad de la señal de radar.....	77
Tabla 3.5. Parámetro de la red neuronal de reconocimiento de patrones.....	89
Tabla 4.1. Errores porcentuales de cálculo de movimiento para el estimador MS y 5% de tolerancia de error.....	93
Tabla 4.2. Errores porcentuales de cálculo de movimiento para el estimador MS y 10% de tolerancia de error.....	93
Tabla 4.3. Errores porcentuales de cálculo de movimiento para el estimador MS y 15% de tolerancia de error.....	94
Tabla 4.4. Errores porcentuales de cálculo de movimiento para el estimador XY-T y 5% de tolerancia de error.....	94
Tabla 4.5. Errores porcentuales de cálculo de movimiento para el estimador XY-T y 10% de tolerancia de error.....	94
Tabla 4.6. Errores porcentuales de cálculo de movimiento para el estimador XY-T y 15% de tolerancia de error.....	94
Tabla 4.7. Errores porcentuales de cálculo de movimiento para el estimador WLS y 5% de tolerancia de error.....	95
Tabla 4.8. Errores porcentuales de cálculo de movimiento para el estimador WLS y 10% de tolerancia de error.....	95
Tabla 4.9. Errores porcentuales de cálculo de movimiento para el estimador WLS y 15% de tolerancia de error.....	95
Tabla 4.10. Matriz de correlación de descriptores.....	100

LISTA DE VARIABLES MATEMÁTICAS

ΔR : Resolución en rango

c : Velocidad de la luz

τ : Pulso de duración de señal emitida

ΔCR : Resolución en rango cruzado

R : Distancia entre el radar y un objetivo

r : Coordenada radial desde el radar al objetivo

θ_{az} : Apertura real de la antena de radar

λ : Longitud de onda de operación del radar

A_r : Largura real de la antena

A_{SAR} : Largura sintética del radar

ΔCR_{SAR} : Resolución en rango cruzado del radar de apertura sintética

v : Velocidad de desplazamiento

T_a : Tiempo de desplazamiento del radar

e : Distancia entre el centro de rotación y la antena del radar

θ_{synt} : Apertura sintética del radar

θ_{real} : Apertura real de la antena con trayectoria de tipo arco

$s(t)$: Señal en el tiempo

$sm(t)$: Señal filtrada por el filtro coincidente

$h(t)$: Función de transferencia del filtro coincidente

A : Amplitud de una señal

f_c : Frecuencia central de operación del radar

K : Constante de onda CHIRP

PRF : Frecuencia de repetición de pulso

f_D : Frecuencia Doppler

v_{pro} : Velocidad promedio del movimiento del radar

x : Coordenada espacial del eje de las abscisas

y : Coordenada espacial del eje de las ordenadas

$f(x, y)$: Matriz de datos

w : Máscara de filtraje

f_{filter} : Resultado de la convolución de una matriz y una máscara

z : Eje de las abscisas en el contexto de regresión lineal

q : Eje de las ordenadas en el contexto de regresión lineal

β : Vector con la información de corte con el eje de las abscisas y pendiente de la regresión

Z : Matriz con todas las posiciones del eje de las abscisas

Q : Matriz con todas las posiciones del eje de las ordenadas

s : Sumatoria de proyecciones de un conjunto de datos sobre una recta

p : Conjunto de puntos que se proyectarán sobre un eje

w : Vector de rotación que proyecta un vector sobre un eje

μ : Media del conjunto de puntos a proyectar

$\tilde{\mu}$: Media del vector de rotación

\tilde{s} : Varianza de s

$J(w)$: Discriminante de Fisher

$h(b)$: Función de activación evaluado en b

co : Matriz de coherencias

co_{scene} : Coherencia propia de la región alumbrada

co_N : Coherencia debido al ruido

Ψ : Fase total de retorno

$\hat{\Psi}$: Sumatoria de fases de retorno

$\bar{\Psi}$: Media de fase de retorno

$\sigma_{\hat{\Psi}}^2$: Varianza de la fase de retorno de $\hat{\Psi}$

k : Instante de medición

θ : Coordenada polar formado por el ángulo entre el eje polar y el objetivo medido

$g_{(R,\theta)}^k$: Matriz de señal de retorno con coordenadas polares en el instante de medición k

$\gamma_{(r,\theta)}^k$: Matriz de fases debidas al movimiento de objetivos con coordenadas polares para cada instante de medición k

$\Delta\gamma$: Variación de fase de movimiento durante un intervalo de tiempo

mov : Movimiento en metros detectado por el radar

$\sigma_{(r,\theta)}^k$: Matriz de fase debido a la reflectividad y distancia de la región alumbrada

$\alpha_{(r,\theta)}^k$: Matriz de fase debido al efecto de fase atmosférica de la región alumbrada

$n_{(r,\theta)}^k$: Matriz de fase debido al ruido de la región alumbrada

$\Psi_{(r,\theta)}^k$: Matriz de fase total en el instante k

G : Contador de tramas sintéticas generadas

$trama_G(t)$: Señal sintética compleja en el tiempo

$A_G(t)$: Amplitud de la señal sintética

$\varphi_G(t)$: Fase de la señal compleja

des^G : Descriptor de calidad

δ_{min}^G : Fase mínima de $trama_G(t)$

δ_{max}^G : Fase máxima de $trama_G(t)$

$Stack(r, \theta, t)$: Stack de datos

A_o : Fase del pixel en estudio con coordenadas r, θ, t

A_{-1} : Fase del pixel vecino al pixel estudiado con coordenadas $r, \theta - 1, t$

A_1 : Fase del pixel vecino al pixel estudiado con coordenadas $r, \theta + 1, t$

$CA_{-1}(r, \theta)$: Matriz de correlación en azimut de un pixel con su vecino de coordenadas $r, \theta - 1, t$

$CA_1(r, \theta)$: Matriz de correlación en azimut de un pixel con su vecino de coordenadas $r, \theta + 1, t$

R_o : Fase del pixel en estudio con coordenadas r, θ, t

R_{-1} : Fase del pixel vecino al pixel estudiado con coordenadas $r, \theta, t - 1$

R_1 : Fase del pixel vecino al pixel estudiado con coordenadas $r, \theta, t + 1$

$CR_{-1}(r, \theta)$: Matriz de correlación en azimut de un pixel con su vecino de coordenadas $r, \theta, t - 1$

$CR_1(r, \theta)$: Matriz de correlación en azimut de un pixel con su vecino de coordenadas $r, \theta, t + 1$

$Mov(r, \theta)$: Matriz de movimientos detectados por el estimador

$trama_{\theta}^r(t)$: Stack de datos que contiene todas los pixeles en azimut, rango y todos los instantes de tiempo de adquisición hasta el tiempo T .

$B_{1\theta}^r(t)$: Stack de datos durante la primera mitad de duración del stack para cada pixel en azimut y rango

$B_{2\theta}^r(t)$: Matriz de fases durante la segunda mitad de duración del stack para cada pixel

$MOV_{MS}(r, \theta)$: Matriz de movimientos detectados con el estimador MS

$V_{1\theta}^r(t)$: Stack de datos durante la primera mitad de duración del stack para cada pixel y sus vecinos en azimut

$V_{2\theta}^r(t)$: Stack de datos durante la segunda mitad de duración del stack para cada pixel y sus vecinos en azimut

$MOV_{XY-T}(r, \theta)$: Matriz de movimientos detectados con el estimador XY-T

D : Vector columna con fases interferométricas de todas las adquisiciones durante el tiempo T

A : Matriz de signos

W : Matriz de coherencias de todos los instantes de tiempo

cov : Covarianza de cada coherencia

Ω : Matriz cuadrada con diagonal igual a cov

C : Vector con parámetros de la recta que aproxima el movimiento por el estimador WLS

$MOV_{WLS}(r, \theta)$: Matriz de movimientos detectados por el estimador WLS

E_{MS}^G : Cantidad de tramas cuyo movimiento no pudo ser detectado correctamente por el estimador MS

E_{XY-T}^G : Cantidad de tramas cuyo movimiento no pudo ser detectado correctamente por el estimador XY-T

E_{WLS}^G : Cantidad de tramas cuyo movimiento no pudo ser detectado correctamente por el estimador WLS

$error_{MS}^G$: Porcentaje de tramas cuyos movimientos no fueron detectados correctamente por el estimador MS

$error_{XY-T}^G$: Porcentaje de tramas cuyos movimientos no fueron detectados correctamente por el estimador XY-T

$error_{WLS}^G$: Porcentaje de tramas cuyos movimientos no fueron detectados correctamente por el estimador WLS

f_{rp} : Función con los pesos sinápticos ya entrenados para la clasificación de calidad de señal

$vel(t)$: Velocidad de desplazamiento de suelos durante el periodo de tiempo T

$acel(t)$: Aceleración del desplazamiento de suelos durante el periodo de tiempo T

J : Cantidad de neuronas utilizadas por la red neurona artificial

RESUMEN

Los deslizamientos son fenómenos naturales que ocurren de manera frecuente, perjudicando a numerosos centros poblados e incluso provocando pérdidas humanas y materiales. Debido a esta problemática, se propone un algoritmo de monitoreo de superficies utilizando señales de radar terrestre de apertura sintética (GBSAR) y técnicas interferométricas para proveer de información sobre el comportamiento de la dinámica de suelos que aporte en la prevención de derrumbes y deslizamientos. Los datos que fueron procesados en este estudio fueron tomados con el radar SENTIR-GEO en Duque de Caxias, estado de Rio de Janeiro, Brasil. Este es un radar compacto, de adquisición continua y que opera en la banda X. La base de datos se construyó con mediciones en un periodo de siete días. El lapso de tiempo sobre el cual se tiene muestras es de aproximadamente seis días y han sido adquiridas durante el periodo de lluvias. El método propuesto para el monitoreo de superficies consta de cinco partes luego de la adquisición de la señal: apilamiento de matrices de información o *stacking*, aplicación de estimación de movimiento, extracción de características espaciales y temporales de las señales adquiridas, clasificación de calidad de la señal y acumulación de movimientos detectados. Aplicando este método a datos simulados, se obtuvieron movimientos de superficies con 95% de precisión y en la clasificación de señal se obtuvo 90.1% de acierto. Utilizando las señales adquiridas en Xerém, en Rio de Janeiro, se detectó que la superficie en evaluación presentaba movimientos de hasta 47 mm, luego de una precipitación, demostrando ser una zona con riesgo a deslizamientos que debe tener la atención de las autoridades pertinentes para evitar catástrofes.

INTRODUCCIÓN

Los derrumbes y deslizamientos son problemas de índole nacional. Investigaciones mostradas en [1] cuantifican el número de derrumbes y deslizamientos a lo largo de los años y demuestran que, ininterrumpidamente, Perú se ve afectado por este fenómeno geológico. El trabajo realizado en [2] muestra un consolidado de susceptibilidad de poblaciones, viviendas y pobladores afectados a lo largo del litoral peruano a partir de las variables que derivan al desencadenamiento del movimiento de suelos. Los datos expuestos en dicho trabajo muestran un total de aproximadamente 9500000 pobladores afectados, y que las provincias más afectadas serían Arequipa y Cajamarca con más de un millón de pobladores damnificados cada una.

Estudios de monitoreo de superficies se han venido realizado en Perú para adquirir mayor información acerca de estos sucesos geodinámicos, pero estos estudios por lo general se hacen con equipos de planta que son bastante pesados en actividad física y peligrosos para los operarios. Esta desventaja en la técnica de recolección de información puede ser subsanada utilizando un sistema activo de monitoreo remoto como es el radar [3].

Desde las últimas décadas, el uso de radares de apertura sintética (SAR) para la detección de movimientos de superficies mediante la técnica de la interferometría ha ido obteniendo atención en la comunidad científica. Esto se debe a la versatilidad de los radares de trabajar bajo diferentes condiciones climáticas y bajo cualquier condición de iluminación por ser el radar un sistema activo que no depende de la luz solar.

En [4] se establece que un radar de monitoreo de riesgos de deslizamientos debe cumplir con las siguientes condiciones:

- 1) Ser robusto y de fácil transporte
- 2) Práctico y eficaz
- 3) Simple y de operación autónoma
- 4) Tener una interfaz gráfica 2D o 3D para visualizar los resultados
- 5) Medir el movimiento acumulado con menos de un centímetro de precisión
- 6) Tener resolución de dos metros aproximadamente
- 7) Cubrir al menos un kilómetro

Además de demostrar que el radar SENTIR-GEO, de banda X, es capaz de medir movimientos en el orden de los milímetros, se busca encontrar una relación entre el movimiento detectado y la presencia y/o ausencia de lluvias en el área de estudio. Este tipo de análisis ayuda a conocer más la dinámica de suelos y su comportamiento luego de cambios climáticos, por consiguiente, a entender cuando una zona con movimientos de suelo está en un estado de alto riesgo.

CAPITULO I

ANTECEDENTES Y DESCRIPCIÓN DEL PROBLEMA

En este capítulo se realiza una mención del estado del arte, así como una descripción de la realidad problemática.

1.1. Antecedentes

Con el fin de hacer el cálculo acertado de movimientos de masa terrestre utilizando radares de apertura sintética, se han propuesto diversas técnicas en el monitoreo de superficies que varían principalmente en el tipo de adquisición de datos, los cuales son: radar aerotransportando, radar satelital o radar montado en el suelo. Cada uno de estos tipos de adquisiciones presenta particularidades técnicas como lo son la varianza espacial [3], errores por el efecto de aproximación a la tierra esférica, ruido speckle y fase de retorno ruidosa.

En los últimos años, el estado del arte en el monitoreo de deformación de suelos demuestra que el uso de señales de radar SAR otorgan resultados provechosos para la geotecnia con la ventaja adicional de ser un sistema activo e independiente de la nubosidad de la zona que se desee alumbrar. Estudios experimentales realizados en [10], utilizan la metodología de *permanent scatterers*, el cual consiste en aminorar el error de medición de movimientos de tierra haciendo el uso de extensas tomas de datos y comparar que zonas son las que presentan menos movimiento a través del tiempo. A partir de ello, se ponderan los datos que tienen mayor o menor correlación entre sí, para hacer el cálculo de la fase de movimiento y posteriormente calcular el movimiento de objetos con respecto al radar.

Para el cálculo de movimiento de objetivos, la información crucial se encuentra en la fase, es por ello, que gran parte del reto en la detección de movimientos está en la estimación de la fase recibida con la mejor relación señal-ruido posible. Diversos estimadores se han propuesto en la literatura y para este trabajo se han implementado tres de ellos y así poder comparar su desempeño.

El primer estimador es el de media simple (MS), que minimiza el ruido multiplicativo asumiendo de que el ruido de fase es Gaussiano y blanco el cual ha sido probado en [5] y mostrando que tiene un desempeño ligeramente superior al filtro de mediana en la

maximización de la relación señal-pico de ruido (PSNR). Este estimador no opera de forma adecuada en el caso de niveles de ruido altos en la señal adquirida. Por otro lado, el segundo estimador llamado coherencia espacio-temporal, es bastante utilizado porque usa una ventana en el espacio y el tiempo para el cálculo de la fase interferométrica, como se mostró en [6], siendo usado en imágenes de radar satelitales, evidenciando su buen desempeño en imágenes de radar con problema de varianza espacial. Sin embargo, este estimador requiere de una alta correlación espacial (en azimut y rango) para cada matriz de datos de señal adquirida, de lo contrario, el ruido de algunos píxeles de la matriz adquirida puede afectar a los píxeles vecinos. Y finalmente, el tercer estimador es el *weighted least squared* (WLS) utilizado en [7]-[8] en imágenes satelitales SAR, basado en los conceptos de W. Ye, donde se demuestra que este método logra estimar correctamente el movimiento efectuado en un intervalo de tiempo, a pesar de la heterogeneidad espacial; siendo que esta produce ruido en las fases en las señales. Si bien este estimador intenta calcular el movimiento de un objetivo de la forma más adecuada posible a pesar del ruido en la señal, siempre existen niveles de ruido que corrompen completamente la información útil. En la literatura actual no existe una etapa de clasificación de señal apta para ser procesada por el algoritmo WLS.

El análisis de desempeño de los estimadores que se han presentado en la literatura fueron realizados con imágenes de resolución superior a la que se dispone en este estudio y no para un escenario de *ground-based* SAR. Esto quiere decir, que las metodologías encontradas en el estado del arte no pueden ser aplicadas directamente en esta aplicación, puesto que necesitan una adaptación al tipo de adquisición de señal y las especificaciones técnicas que se disponen.

Luego de la elección de la estimación de fase, el análisis que corresponde ser efectuado es la correlación que tienen los movimientos de masa geodinámica con los acontecimientos climatológicos y geológicos en esa zona en particular.

En [9] se muestra un estudio comparativo entre los resultados de la aplicación de una red neuronal que utiliza retro propagación para predecir el movimiento de los suelos con respecto a los resultados de cálculo de los instrumentos de campo. Los parámetros de entrada a la red neuronal son datos entregados por sensores in situ (pluviómetros, piezómetro de cuerda vibrante e inclinómetros) además de información sobre la lluvia en el día de la evaluación, 3 días antes de la evaluación y 7 días antes de la evaluación. Una vez escogidos los parámetros de entrada, el autor eligió la arquitectura de la red neuronal de forma heurística. Los resultados predictivos de esta aplicación generaron un 95% de precisión y proporciona información del desplazamiento en el orden de los milímetros. Si bien es cierto que se logra tener un mejor conocimiento de cómo el lugar

censado reacciona a las variables externas, no es posible utilizar este sistema como uno de monitoreo en tiempo real, que cuantifique el movimiento efectivo en intervalos de tiempo específicos.

En el estado del arte se pueden encontrar diversos estudios acerca de la detección de movimientos de masa terrestre utilizando diversos algoritmos que se adaptan al tipo de adquisición de señal que las especificaciones técnicas del radar admiten. Las metodologías encontradas en la literatura no resuelven eficientemente todos los escenarios que se pueden encontrar al momento de utilizar radares GB-SAR para la detección de movimiento de objetos, dentro ellos, el uso de señal de radar en banda X para detección de movimientos de suelo utilizando adquisición de señal del tipo continua.

1.1.1. Situación problemática

El crecimiento desordenado de la población en Perú ha ocasionado la existencia de poblaciones con latente riesgo de ser afectados por un deslizamiento, ya sea por situarse en zonas con pendientes altas y sin obras de protección, por edificar viviendas con materiales inadecuados, o por el desconocimiento de las zonas vulnerables. Como se muestra en la Figura 1.1, la geografía peruana y sus condiciones climatológicas originan, sin cese, constantes deslizamientos a lo largo de los años [11], es por ello que prevenir este tipo de desastre geológico es indispensable para mitigar los daños humanos y materiales que podrían causar




Figura 1.1. Histograma de huaycos y deslizamientos en Perú. Fuente: [11]

Según el documento de trabajo emitido en [2]:

Entre los años 2003 y 2009 las emergencias registradas a nivel nacional ante la ocurrencia de fenómenos de remoción en masa como deslizamientos y derrumbes, se totalizaron 1,391 emergencias, dejando 187 mil personas afectadas, 16 mil personas damnificadas, 4 mil viviendas afectadas y más de 3 mil viviendas destruidas. En términos absolutos el número de personas afectadas y damnificadas se aproxima a 150 mil a causa de deslizamientos. En relación a viviendas afectadas y destruidas a causa de deslizamientos sobrepasa las 5 mil viviendas.

Teniendo en cuenta los precedentes ocurridos en ese lapso de años, el Ministerio del Ambiente consolidó un cuadro de susceptibilidad física de zonas propensas a deslizamientos en la costa y sierra del país. Dicho cuadro evalúa diferentes factores que influyen y evidencian las características naturales de un territorio. Estos factores son: factores litológicos, forma del territorio, pendientes, vegetación y clima.

Se expone dicho consolidado de susceptibilidad a continuación en la Tabla 1.1 en donde se observa que departamentos como Arequipa y Cajamarca tienen una susceptibilidad de más de un millón de habitantes afectados cada uno, e Ica que es el departamento que presenta menos población afectada tiene una susceptibilidad de más de 70 mil personas. Sin dudas, es un tema que afecta a todo el litoral peruano.

Tabla 1.1 Susceptibilidad de pobladores, poblados y viviendas en Perú por deslizamientos.
Fuente: [2].

Departamentos afectados por deslizamientos	Número de centros poblados probablemente	Población probablemente	Número de viviendas probablemente
Amazonas	247	43,294	13,971
Ancash	7011	601,795	198,333
Apurímac	3827	374,764	137,575
Arequipa	4807	1,023,529	301,553
Ayacucho	7064	531,422	197,333
Cajamarca	5177	1,083,232	330,313
Callao	1	277,895	80,434
Cusco	7696	796,876	245,844
Huancavelica	6476	425,561	148,414
Huánuco	5439	337,826	108,181
Ica	478	70,129	24,676
Junín	2725	806,637	232,067
La Libertad	2956	454,646	130,379
Lambayeque	382	55,198	15,053
Lima	4052	772,286	226,929

Moquegua	1234	83,235	33,022
Pasco	2120	181,523	51,782
Piura	2122	589,389	150,120
Puno	7804	812,342	329,783
San Martin	7	75	40
Tacna	635	100,621	32,944
Tumbes	157	70,325	20,067
Total	72417	9,492,600	3,008,813

1.1.2. Formulación del problema

Los deslizamientos son procesos geológicos que suceden a través del tiempo a una velocidad muy lenta pero que una vez llegado el punto crítico en el que los suelos están a punto de derrumbarse, existe poco tiempo para una evacuación ordenada y eficiente. Es por ello que diferentes métodos de monitoreo de movimientos de suelo han sido utilizados para comprender su comportamiento frente a estímulos externos como son las precipitaciones o sismos. Comprender como se comporta una determinada masa terrestre servirá como base para la toma de decisiones ante la aparición de nuevos estímulos externos.

Algunos métodos proponen utilizar equipos de campo en la zona de estudio, pero dicha labor generalmente tiene un alto costo operacional, y es un trabajo físico pesado para los operadores. Otros métodos proponen el uso de radares satelitales para el monitoreo de movimientos de suelo, pero estos no ofrecen la cobertura ininterrumpida que se requiere, por ejemplo, en una zona con una lluvia intensa inminente.

Por lo tanto, existe la necesidad de un sistema de monitoreo de zonas con riesgo de movimiento, durante periodos prolongados de tiempo en los que existan indicios de movimientos de masa terrestre y que opere bajo diferentes condiciones climatológicas, proporcionando información en tiempo real.

Los radares satelitales de apertura sintética son utilizados para la detección de movimientos de suelo y existen metodologías muy robustas para el cálculo del movimiento de suelo, sin embargo, no garantizan una cobertura permanente de una región en particular, por lo que los algoritmos de interferometría no se aplican a esta investigación. Con respecto a la detección de movimientos de suelo durante periodos prolongados como es el caso de los radares GB-SAR, los algoritmos utilizados suelen aprovechar la mayor cantidad de información que se dispone de la misma zona geográfica utilizando medidas estadísticas, sin embargo, los algoritmos no hacen diferencia entre señales libres de ruido y señales corruptas por el ruido. Es decir, que

no se dispone de un algoritmo de clasificación de calidad de señal para garantizar que el movimiento detectado es fiable.

Como conclusión, no se dispone de un método que calcule los movimientos de suelo utilizando procesamiento de señal de radar de un GB-SAR de banda X y que tenga una etapa de clasificación de calidad de señal para descartar los movimientos detectados de forma errónea debido al ruido.

1.1.3. Justificación e importancia de la investigación

Con la finalidad de monitorear los movimientos superficiales tanto en ciudades como en montañas, glaciares o volcanes, se utilizan radares satelitales para la adquisición de datos y técnicas interferométricas para el cálculo de la información deseada. Los radares satelitales generalmente adquieren información de una misma zona geográfica en un intervalo de tiempo grande [22], a este tipo de adquisición se le conoce como adquisición de tipo discreta, y ha sido ampliamente estudiada [30]. Sin embargo, existe poca literatura orientada al monitoreo de masa terrestre utilizando radares montados en el suelo, con adquisición de datos de tipo continua, por lo que es un tema complejo que aún se encuentra en etapa de experimentación y desarrollo.

La importancia de tener un sistema en tiempo real de monitoreo de suelos que garantice la detección precisa de los movimientos de hasta un kilómetro de alcance radica en la mitigación de pérdidas humanas y materiales que las autoridades pertinentes pueden proporcionar obteniendo información acerca de la dinámica de suelo de una zona en riesgo a deslizarse.

1.1.4. Objetivos

Se propone un objetivo general y tres objetivos específicos, los cuales son mencionados a continuación.

1.1.5. Objetivo general

Caracterizar los procesos geodinámicos de superficies con presencia de precipitaciones de hasta un kilómetro de alcance, utilizando señales del radar de apertura sintética SENTIR-GEO de banda X montado en el suelo y así generar información acerca de los movimientos de suelos para que sirva de apoyo en la toma de decisiones de sistemas de alerta temprana de deslizamientos.

1.1.6. Objetivos específicos

Se plantean los siguientes objetivos específicos:

- 1) Hallar un estimador de movimientos que obtenga el menor error porcentual utilizando señales de radar de banda X y adquisición de tipo continuo.
- 2) Hallar el tiempo de integración óptimo en el que el estimador de movimientos pueda operar en tiempo real.
- 3) Clasificar la calidad de las señales adquiridas para descartar los movimientos ocasionados por distorsiones.

1.1.7. Hipótesis

Se propone una hipótesis general y tres hipótesis específicas. Dichas hipótesis son detalladas a continuación.

1.1.8. Hipótesis general

La caracterización de los procesos geodinámicos de superficies utilizando un radar de apertura sintética montado en el suelo y de banda X, proporciona información acerca de la tendencia de movimientos de suelos y velocidad a la que estas se producen en un área de hasta un kilómetro de alcance.

1.1.9. Hipótesis específicas

Se plantean las siguientes hipótesis específicas:

- 1) Existe un estimador de movimientos con el cual se consigue hallar la mayor cantidad de movimientos de forma acertada a pesar de las distorsiones debido al ruido *speckle*, saltos de fase y baja correlación espacial.
- 2) El tiempo de integración adecuado para el cálculo de movimientos permite utilizar la metodología en tiempo real sin incurrir en ambigüedades.
- 3) Existen descriptores de calidad espaciales y temporales que describen si las tramas de señal son aptas para el cálculo de movimientos

1.1.10. Variables e indicadores

1.1.11. Del objetivo general

- Variable dependiente: señales de radar ruidosas cuya información contiene movimientos de superficies de suelo que deben ocasionar deslizamientos.
- Variable independiente: geodinámica de la superficie en estudio. Precipitaciones previas y durante la toma de datos.

1.1.12. De los objetivos específicos

En la Tabla 1.2 se muestra el resumen de las variables dependiente e independiente para cada objetivo específico y también los indicadores que contrastan su análisis.

Tabla 1.2. Variables e Indicadores por Objetivo Específico.

	Variable dependiente	Variable independiente	Indicadores
Objetivo específico 1	Movimientos de suelos	Señal de radar de banda X	Error medio porcentual en el desempeño de los estimadores de movimiento
Objetivo específico 2	Tiempo de procesamiento del método aplicado a un stack.	Tiempo de integración de señales para el cálculo de movimientos.	Tasa de relación del tiempo de procesamiento versus tiempo de integración menor a uno.
Objetivo específico 3	Calidad de la señal adquirida	Señales adquiridas de banda X	Nueve descriptores de calidad de señal

1.2. Unidad de análisis

En este subcapítulo se comenta la localización en la cual fue adquirida la señal de radar y bajo qué condiciones climatológicas.

1.2.1. Ubicación

El lugar elegido para el experimento es propenso a sufrir un deslizamiento, esta zona está situada en el distrito de Duque de Caxias, estado de Rio de Janeiro, Brasil. Esta ciudad presenta lluvias bastante fuertes durante el periodo de verano (de diciembre hasta fines de febrero) y es necesario estudiar la relación entre las precipitaciones y el movimiento de la masa terrestre.

El radar se encuentra situado exactamente en 22°34'9.09" S y 43°18'47.80" W a 32 metros sobre el nivel del mar, a 100 metros de la "escarpa principal" que será analizada por el radar.

1.2.2. Toma de datos

El experimento fue planeado para realizarse durante la época de más volumen de lluvias. La campaña se realizó entre el 15 y el 22 de febrero del 2016. Los datos que se obtuvieron en este periodo tuvieron brechas sin captura por problemas técnicos. Por lo que se disponen de 3 tomas de datos grandes, la primera de 13 horas de grabación, la segunda de 47 horas de grabación y la tercera de 46 horas. Durante estos días ocurrieron diversas lluvias con diferente volumen de precipitación, desde lluvia leve hasta lluvia torrencial, para lo cual utilizamos la Tabla 1.3 que resume y clasifica el volumen de lluvias en el periodo mencionado.

Tabla 1.3 Clasificación de lluvias en el periodo de toma de datos

Tipo	Intensidad (mm/h)
Torrencial	> 30
Intensa	15 - 30
Fuerte	7.5 - 15
Moderada	2.5 - 7.5
Leve	0.01 - 2.5

CAPITULO II

MARCO TEÓRICO Y CONCEPTUAL

En este capítulo se realiza una mención los conceptos y tópicos necesarios para la comprensión y desarrollo del presente trabajo de investigación.

2.1. Sistema de radar

Utilizando las definiciones de [12] un sistema de radar trabaja generando y transmitiendo ondas electromagnéticas a un objetivo específico. Este objetivo refleja la onda con menos poder y con fase cambiada, la cual puede ser detectada y procesada. Los radares han sido desarrollados por décadas para diferentes aplicaciones como la detección de objetivos, medida de distancias, medida de velocidades, etc.

2.1.1. Tipos de radar según señal emitida

Los tipos de señales emitidas por un sistema de radar pueden ser clasificadas en dos grandes grupos: de onda continua o de onda discreta (radar de pulsos). En las señales de onda continua, tenemos el receptor transmitiendo constantemente. En esta configuración el receptor debe ser aislado por periodos de tiempo para que se pueda procesar la señal recibida. Por otro lado, las señales de tipo pulsante se generan emitiendo una pequeña porción de señal seguido de un tiempo muerto o “apagado” del transmisor que servirá como tiempo de escucha.

2.1.2. Configuraciones básicas de radar

Existen dos tipos de configuraciones básicas en la disposición de las antenas de un sistema de radar; monoestática y biestática. En la configuración monoestática, una antena sirve como transmisor y receptor a la vez. En la configuración biestática, el transmisor y receptor están separados físicamente. El principal criterio para separar el emisor y receptor es la potencia emitida, la cual puede causar altos niveles de ruido en el receptor, el cual posee componentes sensibles a bajos niveles de potencia de señal.

2.1.3. Imágenes de radar

Intuitivamente las imágenes ópticas proveen información más fácil de interpretar con respecto a las imágenes de radar. El ojo humano está acostumbrado a las imágenes a full color y no al formato de blanco y negro que tienen las imágenes de radar.

Sin embargo, las imágenes de radar tienen ciertas ventajas sobre las imágenes ópticas. Al ser el radar un sistema activo, puede operar bajo diferentes condiciones luminosas y, según la longitud de onda, bajo diferentes condiciones atmosféricas. Además, las imágenes de radar permiten obtener modelos de elevación de un territorio y las variaciones que suceden en la superficie de este a través del tiempo.

2.1.4. Resolución

El concepto de resolución de radar es la habilidad de distinguir dos o más objetivos que están espacialmente cerca. Supongamos que estos objetivos emiten ecos que son recibidos por la antena del radar, la distancia medida debe ser ΔR . Si ΔR es lo suficientemente largo, los dos objetos serán discriminados correctamente. Por el contrario, si ΔR es una distancia muy corta, los objetos serán indistinguibles, a esto se le conoce como un sistema no resuelto. La distancia ΔR , cumple la siguiente igualdad:

$$\Delta R = \frac{c\tau}{2} \quad (1)$$

Entonces, la distancia mínima de separación medida sin ambigüedad para un pulso de duración τ será de $\frac{2\Delta R}{c}$.

2.1.5. Azimut y rango

El azimut o trayectoria está definido por el desplazamiento el escaneo del radar. El rango, por el contrario, está relacionado con el ángulo de elevación que el radar tiene y el alcance que tiene la señal sobre el área de interés. La Figura 2.1 muestra estos conceptos para el GB-SAR de tipo rotatorio.




Figura 2.1. Geometría de la adquisición de datos para un SAR rotatorio

2.2. Radar de apertura sintética

Según la definición utilizada en [13], el radar de apertura sintética es un dispositivo de microondas activo que permite generar imágenes de alta resolución en varios barridos de la antena para recrear un solo "barrido virtual". El mismo emite señales de microondas a intervalos regulares sobre una región de interés, recibe la parte de esta energía que es retrodispersada desde dicha región y detecta la intensidad y la distancia, es decir el retardo en el tiempo, de las señales de retorno.

El radar posee su propia fuente de energía y, por lo tanto, es independiente de la luz del sol para la iluminación. Este tipo de sistema se conoce como sistema de teledetección activo. La gran ventaja del radar sobre los sensores ópticos es la posibilidad de funcionar tanto de día como de noche y la de atravesar las capas de nubes, lo que implica una gran disponibilidad de información.

Estos hechos, junto con la sensibilidad a la rugosidad de la superficie y al contenido de humedad del suelo, (debido a las longitudes de onda en que emite el radar), significan que el SAR es una herramienta muy poderosa en sensoramiento remoto. Dadas sus características puede distinguir diferentes tipos de cobertura de la Tierra, así como también puede detectar cambios temporales, de gran utilidad, por ejemplo, en agricultura.

Para comprender mejor el concepto de radar de apertura sintética, se procede a explicar el funcionamiento de un radar de apertura real. Un radar de apertura real tiene un ancho de haz θ_{az} , asociado al patrón de radiación de la antena. Este ancho de haz involucra el área cubierta por el haz en el sentido perpendicular del rango del radar, la cual se conoce como rango cruzado o *cross-range* y la resolución asociada a ella como ΔCR . Supongamos un escenario como en la Figura 2.2, donde el radar se encuentra en la punta de un avión, en la Figura 2.2a existen dos objetivos a una distancia R_0 , donde la resolución del rango cruzado no permitirá que los objetos sean detectados de forma correcta, ya que a la misma distancia se confundirán como un solo objeto. En la Figura 2.2b, los objetos están separados a una distancia mayor que ΔCR por lo que si podrán ser detectados como dos objetos diferentes.

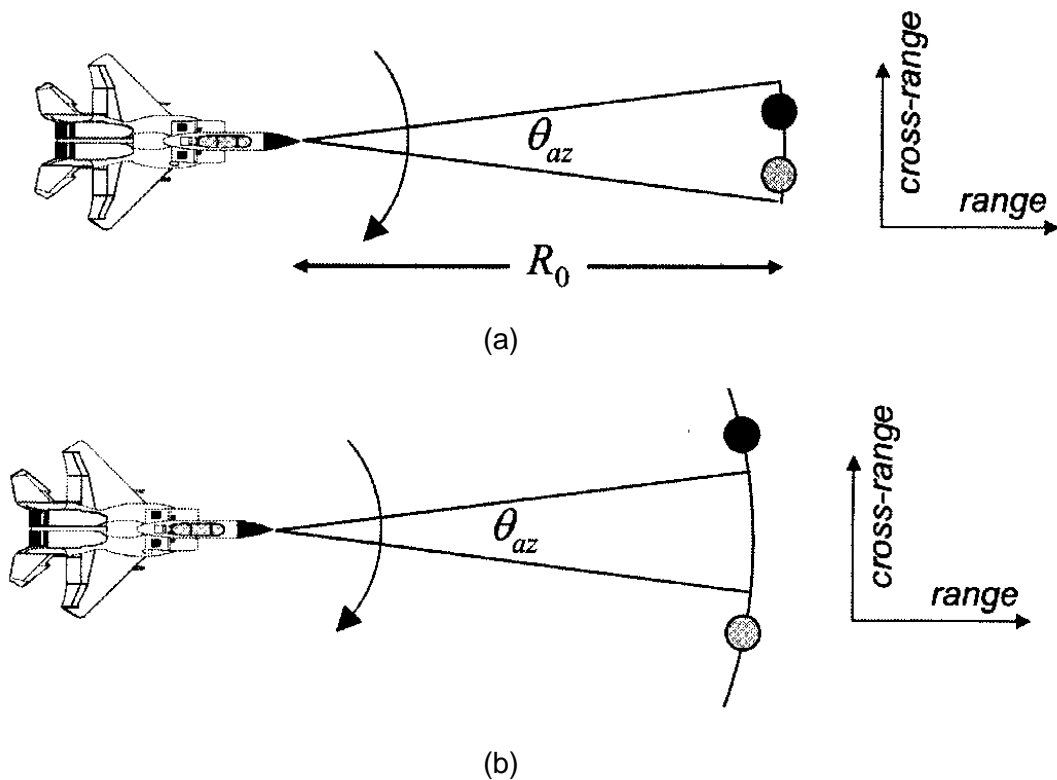


Figura 2.2. Resolución de *cross-range* de un radar (a) Ambigüedad en la detección de dos objetos (b) No ambigüedad en la detección de objetos.

La ecuación que relaciona el ancho de haz con la resolución cruzada es la siguiente:

$$\Delta CR = R\theta_{az}, = \lambda R/A_r \quad (2)$$

Donde $\theta_{az} = \lambda/A_r$, λ es la longitud de onda a la que opera el radar y A_r la largura de la antena. La resolución del *cross-range* es dependiente del rango y una forma de obtener una mejora de esta resolución, sin modificar la longitud de onda de operación del radar, sería aumentar la largura de la antena. Como ejemplo, se tiene un radar de

banda X con alcance de hasta 10 km en rango y un tamaño de antena de un metro, esto origina un ΔCR de 300 m, siendo una resolución que no proporciona información útil. En el caso de querer una resolución de 3 m, la largura de la antena debería ser de 100 m, la cual la hace inviable. Por lo tanto, surge la necesidad de incrementar la resolución en *cross-range* sin tener que incrementar el tamaño de la antena ni modificar la longitud de onda.

Con la limitación de no modificar la frecuencia de operación y no incrementar demasiado la largura de la antena, una forma de conseguir una mejora en la resolución del *cross-range* es utilizar un arreglo de antenas. Una forma muy ingeniosa de simular un arreglo de antenas, es utilizar la misma antena y moverla sobre una plataforma con el fin de simular diferentes sensores en distintas posiciones. Utilizando esta técnica, el algoritmo de recolección de señal es el siguiente: capturar señal una posición del radar, almacenar la información, desplazar el radar y volver al primer paso. En la Figura 2.3 se muestra un avión y todas las posiciones por las que el radar va a pasar. Una vez colectada la información, se procede a la etapa de integración, donde todos los pixeles que corresponden a la misma posición son integrados de forma coherente. Esta repetición de observaciones del mismo objeto se puede apreciar en la Figura 2.4.

Es decir, se simula una antena con largura igual a la trayectoria del radar y por procesamiento se realiza la composición de la matriz de datos coherente.




Figura 2.3. Movimiento del radar para generar un arreglo de radares sintético.




Figura 2.4. Repetición de información acerca de un objetivo debido al movimiento del radar.

Como el radar obtenido luego del procesamiento tiene una largura de tamaño diferente y por consiguiente una apertura o ancho de haz distinta, a esta se le conoce como apertura sintética, de ahí el nombre de radar de apertura sintética.

Haciendo un análisis del radar simulado, se tiene que la nueva largura es la siguiente:

$$A_{SAR} = vT_a \quad (3)$$

Donde A_{SAR} es la largura del radar de apertura sintética, v es la velocidad de desplazamiento del radar y T_a es el tiempo de desplazamiento.

La nueva resolución cruzada del radar de apertura sintética será:

$$\Delta CR_{SAR} = \frac{\lambda R}{2A_{SAR}} = \frac{\lambda R}{2vT_a} \quad (4)$$

Una consecuencia del movimiento del radar es que para mayores distancias, en rango, mayor es la apertura sintética del radar, y para R bastante alto la resolución del *cross-range* en SAR es prácticamente constante.

Con el concepto claro de radar de apertura sintética y como se genera con el movimiento del radar, se extrapola el conocimiento previamente explicado para una trayectoria del radar en forma de arco, el cual se presenta en la Figura 2.5. El radar ubicado a una distancia r desde un centro de rotación y con apertura real de la antena de θ_{real} .




Figura 2.5. Radar de apertura sintética con trayectoria de tipo arco.

La apertura que se consigue con este tipo de configuración está definida por la siguiente expresión:

$$\theta_{synt} = \frac{\lambda}{2 e \theta_{real}} \quad (5)$$

Y la resolución en *cross-range* será mejorada de la misma forma que el radar de apertura sintética con trayectoria lineal.

La configuración de radar de apertura sintética cuya trayectoria es un arco, será utilizada para el desarrollo de la tesis, ya que se dispone del radar rotatorio para la adquisición de señal de este trabajo de tesis.

2.2.1. Escaneo de SAR

En la técnica de recolección de datos de señales SAR existen dos modos de operación fundamentales: recolección de foco concentrado (*spotligh* o modo continuo) y recolección de tira de mapa (*strip-map* o modo discreto). La recolección de foco concentrado tiene por finalidad el escaneo de un territorio pequeño en extensión, pero visto por el radar repetidas veces en intervalos cortos de tiempo (típico en sistemas de monitoreo) mientras que la recolección de tira de mapa teóricamente tiene un escaneo infinito en el sentido de movimiento del radar (azimut).

Los escaneos de tira de mapa presentan una resolución en azimut con menor calidad que los escaneos de foco concentrado para un mismo tiempo de integración. Además, los escaneos de tira de mapa no tienen la capacidad de alumbrar el mismo territorio durante periodos de tiempo cortos y en caso de realizar este proceso, el ruido que se adiciona debido a las perturbaciones en el movimiento, es difícil de eliminar en su totalidad por las diferencias de velocidad del radar y sus coordenadas espaciales.

Generalmente, los escaneos de tira de mapa son realizados en campañas aerotransportadas de toma de datos o mediante radares satelitales. Mientras que los escaneos de foco concentrado son utilizados en radares montados en el suelo, sean para el monitoreo de deslizamientos o en el caso de radares SAR meteorológicos para pronosticar las condiciones climatológicas.

2.2.2. Filtro coincidente

En el contexto de los filtros de coincidencia, la convolución es una operación matemática bastante importante. La convolución lineal puede ser usada para aplicar filtros de coincidencia en el dominio del tiempo. En algunos libros es común encontrar a los filtros de coincidencia como filtros de convolución ya que la salida del filtro es igual a la convolución de las señales de entrada al sistema.

Sea $s(t)$ una señal con características de amplitud y fase, y la deseamos en su forma comprimida $sm(t)$. El filtro de coincidencia $h(t)$ es utilizado para este propósito. Se hace coincidir al filtro con la señal deseada $s(t)$, luego, se invierte la señal en el tiempo y se conjugan las fases. Es así como la señal $s(t)$ es convolucionada con el filtro $h(t)$ para obtener la señal comprimida $sm(t)$ deseada.

2.2.3. Señal CHIRP

Se les llama señales lineales FM por su relación de frecuencia y tiempo. La frecuencia de una señal CHIRP incrementa o disminuye con el tiempo, es así, como la frecuencia instantánea de una señal CHIRP es una función lineal a través del tiempo.

Si una señal CHIRP es puesta como señal de entrada a un altavoz, sonará como el piar de las aves (o *chirping* en inglés) y es por ello que obtiene ese nombre. Posteriormente su nombre se convirtió en las siglas de *Compressed High Intensity Radar Pulse*.

La expresión de la señal CHIRP es la siguiente:

$$s(t) = A \operatorname{rect}\left(\frac{t}{\tau}\right) e^{j(2\pi f_c t + \pi K t^2)} \quad (3)$$

Donde la función *rect* es una función rectangular a través del tiempo t con duración τ . f_c es la frecuencia central del ancho de frecuencias utilizadas, K es llamada la constante CHIRP (Hz^2) que es la relación entre el ancho de banda B y el tiempo de duración de la función rectangular. En la Figura 2.6 se muestra la parte real de una señal CHIRP y en la Figura 2.7 su espectro.




Figura 2.6. Señal CHIRP en el tiempo (parte real).




Figura 2.7. Espectro de la señal.

2.2.4. Enfoque de imágenes de radar

El enfoque de imágenes de SAR consiste en la mejora de la calidad de la resolución espacial de los píxeles. Este proceso consta de dos pasos fundamentales: La compresión de pulso en rango y la compresión en azimut.

2.2.5. Compresión de pulso

La calidad de la imagen es un criterio muy importante en el proceso de formación de imágenes SAR. La resolución del radar debe ser la mayor posible para garantizar una buena calidad de imagen.

Con el fin de observar sin ambigüedad dos objetos se suelen utilizar pulsos de corta duración. Idealmente, la señal emitida debería ser un pulso de Dirac para poder tener la mejor resolución en el sentido del rango, pero como este proceso no es factible en la realidad, se utiliza el criterio de compresión de la señal CHIRP. Este proceso consiste en convolucionar los ecos generados por la señal CHIRP contra los objetos alumbrados y la señal CHIRP transmitida conjugada. De esta manera se consigue mejorar la resolución espacial de la imagen, maximizar la relación señal ruido y evitar ambigüedades tanto como sea posible.

Para los sistemas SAR el pulso de duración es inversamente proporcional a la frecuencia de repetición de pulso (PRF), por ello, los pulsos de corta duración se consiguen usando un alto PRF .

Existe un umbral mínimo en la selección del valor de PRF . La mitad PRF debe ser mayor o igual a la frecuencia Doppler f_D como se muestra a continuación:

$$\frac{PRF}{2} = f_D \quad (5)$$

La ecuación de la frecuencia Doppler es:

$$f_D = \frac{v_{pro}}{c} f_{max} \sin\left(\frac{\theta}{2}\right) \quad (6)$$

Donde, V_{pro} es la velocidad promedio de la plataforma donde se encuentra el radar, f_{max} es el límite superior de frecuencias de la banda, θ es el ángulo de apertura y c la velocidad de la luz.

Como se mencionó anteriormente, el pulso comprimido se consigue con la técnica del filtro coincidente o *matched filter* y la forma de la señal resultante se muestra en la Figura 2.8.




Figura 2.8. Señal CHIRP comprimida mediante la técnica del filtro de coincidencia.

2.2.6. Compresión en azimut

La compresión en azimut en la composición de una imagen SAR es utilizada para reducir el histórico de amplitud y fase generada por las ondas emitidas durante el tiempo en el que un objetivo es alumbrado por el radar. Este proceso consigue mejorar la resolución en azimut utilizando una variación del filtro de coincidencia.

El histórico de fase de un objeto visto por un radar de apertura sintética es idealmente una hipérbola y su dimensión depende de algunos parámetros como la distancia del radar al objetivo, la apertura de la antena, la velocidad a la que se desplaza la plataforma del radar, etc.

La máscara utilizada para la compresión en rango es una matriz con dimensión igual a la hipérbola definida por el histórico de fase, con amplitud normalizada, pero con fase conjugada. En la Figura 2.9(a) se muestra una señal sintética e ideal de un histórico de fase y en Figura 2.9(b) la máscara a utilizar para filtrar y comprimir en azimut.




Figura 2.9. Histórico de fase ideal y máscara para comprimir.

En la práctica, la hipérbola tiene un ancho definido por la calidad de compresión del pulso en rango por lo que también es común convolucionar en el sentido del rango una trama de coeficientes que definan el lóbulo central de la señal Sinc aproximada.

Entonces, el proceso de compresión se realiza correlacionando cada columna en rango de la máscara una a una con las columnas de la matriz con el histórico de fase. Luego, se realiza la sumatoria de todos los vectores columna generados por la convolución previa se obtiene un vector comprimido. En la Figura 2.10 se muestra un histórico de fases comprimido.




Figura 2.10 Compresión en azimut

De la misma manera que en la compresión de pulso en rango, se utiliza el concepto de filtro de coincidencia para obtener un máximo en el momento en el que la máscara se desplace exactamente sobre el histórico de fase del objeto alumbrado. Cabe resaltar que las hipérbolas tendrán diferente ancho y duración dependiendo de la distancia y velocidad del radar hacia el objetivo.

2.3. Filtros espaciales

Los filtros espaciales en el ámbito del procesamiento digital de imágenes son utilizados principalmente para suavizar una imagen, eliminar ruido, realzar característica de la imagen o detectar bordes. En todos estos casos, el procesamiento se realiza utilizando un grupo de píxeles.

Existen dos tipos de filtros en el caso de los filtros espaciales y estos son los filtros lineales y los filtros no lineales. En ambos casos se requiere del uso de una máscara (también conocido como ventana o *kernel*) que define una región de píxeles (ver Figura 2.11) con las cuales se realizará el proceso de filtrado.

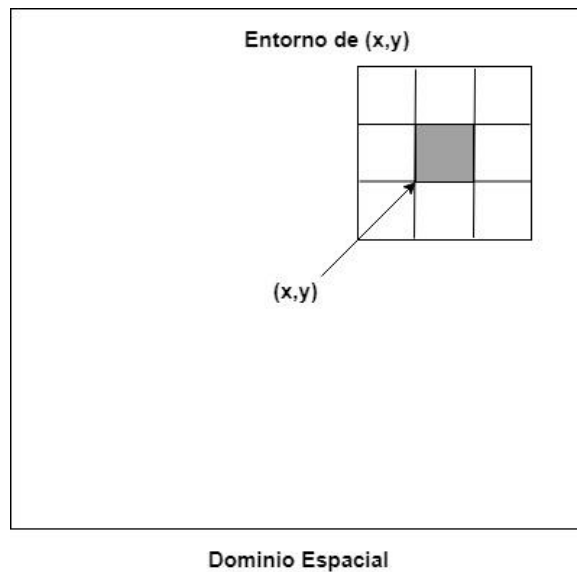


Figura 2.11. Filtro espacial.

En el caso de los filtros lineales, el procesamiento se realiza con la suma de productos de la máscara con una porción de la imagen. Por ejemplo se define en la Figura 2.12 la máscara w que procesará a la imagen $f(x, y)$. El resultado f_{filter} de filtrar $f(x, y)$ con la máscara w se define a continuación:

$$f_{filter} = f(x - 1, y - 1)w(-1, -1) + f(x - 1, y)w(-1, 0) + \dots + f(x, y)w(0, 0) + \dots \quad (7) \\ + \dots + f(x + 1, y)w(1, 0) + f(x + 1, y + 1)w(1, 1)$$

$w(-1,-1)$	$w(-1,0)$	$w(-1,1)$	$f(x-1,y-1)$	$f(x-1,y)$	$f(x-1,y)$
$w(0,-1)$	$w(0,0)$	$w(0,1)$	$f(x,y-1)$	$f(x,y)$	$f(x,y+1)$
$w(1,-1)$	$w(1,0)$	$w(1,1)$	$f(x+1,y-1)$	$f(x+1,y)$	$f(x+1,y+1)$

Figura 2.12 Máscara y porción de imagen a ser filtrada.

Este tipo de filtro es muy usado para la difuminación de bordes y eliminación del ruido aditivo.

Los filtros no lineales, en cambio, utilizan las máscara para definir los pixeles que serán organizados de forma ascendente o descendente y el resultado es definido por algún criterio de elección previamente establecido. Como ejemplo, el filtro de mediana organiza los pixeles en un vector y el resultado es igual al pixel que ocupa la posición central (en el caso de una ventana de 3x3 el resultado será la posición número 5 y en una ventana de 7x7 será la posición 25). Comúnmente las ventanas son de dimensiones espaciales impares tanto para el eje de las abscisas como de las ordenadas y es utilizado para la eliminación del ruido impulsivo o también conocido como ruido sal y pimienta.

2.4. Regresión lineal

La regresión lineal es un modelo que describe la relación entre dos variables numéricas. La regresión lineal ajusta las respuestas de una variable a un modelo lineal, utilizando coeficientes que describan su tendencia. El ajuste por regresión más común es el de mínimos cuadrados, que puede ajustarse tanto a líneas como a polinomios.

La regresión lineal modela la relación entre una variable dependiente y y una variable independiente x . La regresión lineal simple considera solo una variable independiente usando la relación:

$$q = \beta_0 + \beta_1 z + \epsilon \quad (8)$$

Donde β_0 es la intersección con z , β_1 es el coeficiente de regresión o pendiente y ϵ es el término de error. Si usamos un conjunto de n valores de z y q ($\{z_1, q_1\}, \{z_2, q_2\}, \dots, \{z_n, q_n\}$), entonces, se forma con ellos un sistema de ecuaciones lineales que representados en forma matricial queda de la siguiente manera:

$$\mathbf{Z} = \begin{bmatrix} z_1 & 1 \\ z_2 & 1 \\ z_3 & 1 \\ \vdots & \vdots \\ z_n & 1 \end{bmatrix}, \quad \mathbf{Q} = \begin{bmatrix} q_1 \\ q_2 \\ q_3 \\ \vdots \\ q_n \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$$

De tal manera que

$$\mathbf{Q} = \mathbf{Z}\boldsymbol{\beta} \quad (9)$$

Despejando $\boldsymbol{\beta}$:

$$\boldsymbol{\beta} = (\mathbf{Z}^T\mathbf{Z})^{-1}\mathbf{Z}^T\mathbf{Q} \quad (10)$$

Si bien este es el caso más simple de regresión lineal, existe una variación más óptima para datos con varianza alta como es el caso de las señales de radar de apertura sintética. Esta mejora sucede en la ponderación de cada par de datos (variable dependiente y variable independiente) según su calidad, para lo cual se le asigna un peso a cada par de datos para determinar su influencia sobre el modelo de ajuste lineal.

Asumiendo que W es la diagonal de la matriz w , tenemos:

$$\boldsymbol{\beta} = (\mathbf{Z}\mathbf{W}\mathbf{Z})^{-1}\mathbf{Z}^T\mathbf{W}\mathbf{Q} \quad (11)$$

Se recomienda utilizar un coeficiente de correlación para garantizar el ajuste correcto de los datos a un modelo lineal.

2.5. Análisis de discriminación lineal

Es un método de reducción de dimensión y clasificador utilizado mayormente en estadística, aprendizaje de máquina y reconocimiento de patrones.

Supongamos que tenemos un conjunto de puntos $\{p_1, p_2, p_3, \dots, p_m\}$ que se desea proyectar sobre una recta. La distancia promedio desde los puntos p hasta la recta darán como resultado un escalar s . Se tiene entonces:

$$s = w^T p \quad (12)$$

Donde:

$$w = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_m \end{bmatrix} \text{ y } p = \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_m \end{bmatrix}$$

Este método busca encontrar la mejor proyección del conjunto de puntos p para maximizar la separación entre las clases de elementos.

Para ello debemos hallar la media μ_i de los puntos p que pertenecen a cada clase i

$$\mu_i = \frac{1}{N_i} \sum_{p \in \omega_i} p \quad (13)$$

Y de forma similar se halla la media $\tilde{\mu}_i$ para s

$$\tilde{\mu}_i = \frac{1}{N_i} \sum_{s \in \omega_i} s = w^T \mu_i \quad (14)$$

Sin embargo, solo las medias no dan una buena noción de la mejor separabilidad de las clases sobre la proyección de una recta, por lo cual, se calcula la varianza de s .

$$\tilde{s}_i^2 = \sum_{s \in \omega_i} (s - \tilde{\mu}_i)^2 \quad (15)$$

Sin perder generalidad, se hará el cálculo demostrativo para 2 clases. Definimos el discriminante de Fisher como:

$$J(w) = \frac{|\tilde{\mu}_1 - \tilde{\mu}_2|^2}{\tilde{s}_1^2 - \tilde{s}_2^2} \quad (16)$$

Para maximizar $J(w)$ con w^* que maximiza la separabilidad debe ser expresando en función de w .

Se define ahora la matriz de elementos dispersores S_w

$$S_i = \sum_{p \in \omega_i} (p - \tilde{\mu}_i)(p - \tilde{\mu}_i)^T \quad (17)$$

$$S_w = S_1 + S_2 \quad (18)$$

Donde S_i es la matriz de covarianza de la clase i . Si expresamos la varianza en términos de S_i , tenemos:

$$\tilde{s}_1^2 - \tilde{s}_2^2 = w^T S_w w \quad (19)$$

De la misma manera, la diferencia de medias se expresa como

$$\tilde{\mu}_1 - \tilde{\mu}_2 = w^T S_B w \quad (20)$$

Con $S_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T$. El discriminante de Fisher se puede reescribir así:

$$J(w) = \frac{w^T S_B w}{w^T S_w w} \quad (21)$$

Y maximizando $J(w)$, se deriva e iguala a 0.

$$\frac{dJ(w)}{dw} = \frac{d}{dw} \left(\frac{w^T S_B w}{w^T S_w w} \right) = 0 \quad (22)$$

Resolviendo se obtiene:

$$S_w^{-1} S_B w = J(w) w \quad (23)$$

Finalmente, la mejor proyección w^* será el auto valor máximo de las soluciones de la Ecuación (23).

A continuación, se muestra un breve ejemplo visual para mostrar el funcionamiento del algoritmo LDA.

Supongamos un grupo de elementos que fueron clasificados en dos categorías diferentes, es decir, se conoce *a priori* la categoría a la cual pertenece cada elemento. Además de la categoría a la que pertenece cada elemento, se conocen características de ellos. En este caso, se utilizarán dos características que podrían tener cualquier tipo de unidades. Si se ubica cada elemento sobre un plano bidimensional (donde cada eje es el rango de las características que se tiene de los elementos) y coloreamos de diferentes colores según la categoría a la que pertenece cada elemento, obtenemos una representación gráfica similar a la vista en la Figura 2.13a (omitiendo la recta de color morado). La tarea del algoritmo LDA es encontrar un vector de rotación tal que se maximice la separación de las dos categorías. Una vez hecho el cálculo de este vector de rotación, nuevos elementos podrían ser clasificados de forma adecuada.

En la Figura 2.13a se muestra el funcionamiento del algoritmo LDA para la separación de dos clases usando el auto vector más pequeño (recta de color morado), en la Figura 2.13b se generan dos campanas de Gauss con la nueva media y la nueva varianza de la proyección de las características sobre el vector de rotación. Como es de esperarse, la maximización de separación de medias de las categorías no se logró.

Por el contrario, en la Figura 2.14a se muestra la separación de las dos clases usando el auto vector más grande (recta de color verde). De la misma manera, en la Figura 2.14b se generaron campanas de Gauss con la nueva media y la nueva varianza de las proyecciones de las categorías sobre el vector de rotación. Esta vez, se consiguió de forma satisfactoria separar las categorías maximizando la separación entre las medias.

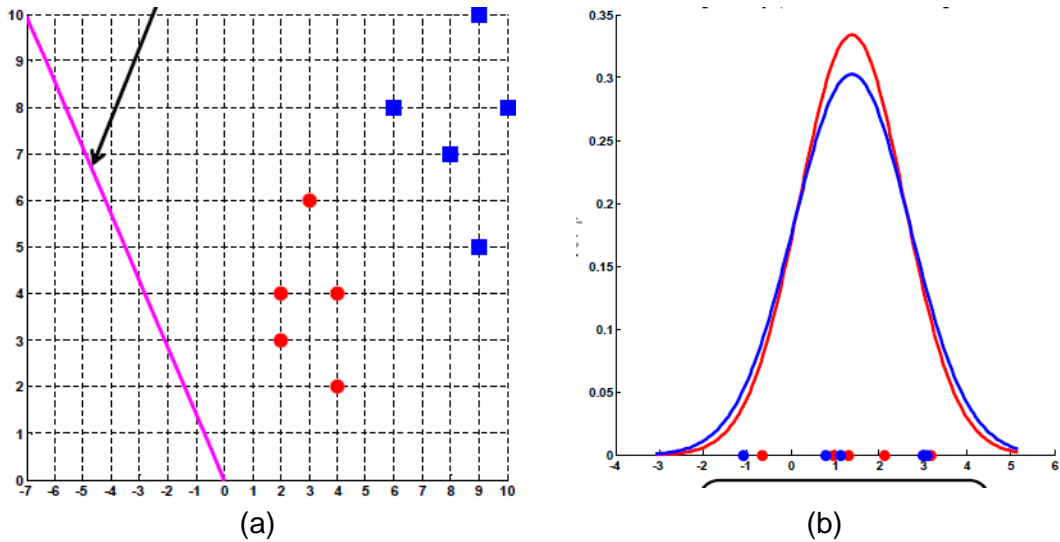


Figura 2.13. Algoritmo LDA usando el mínimo auto valor.

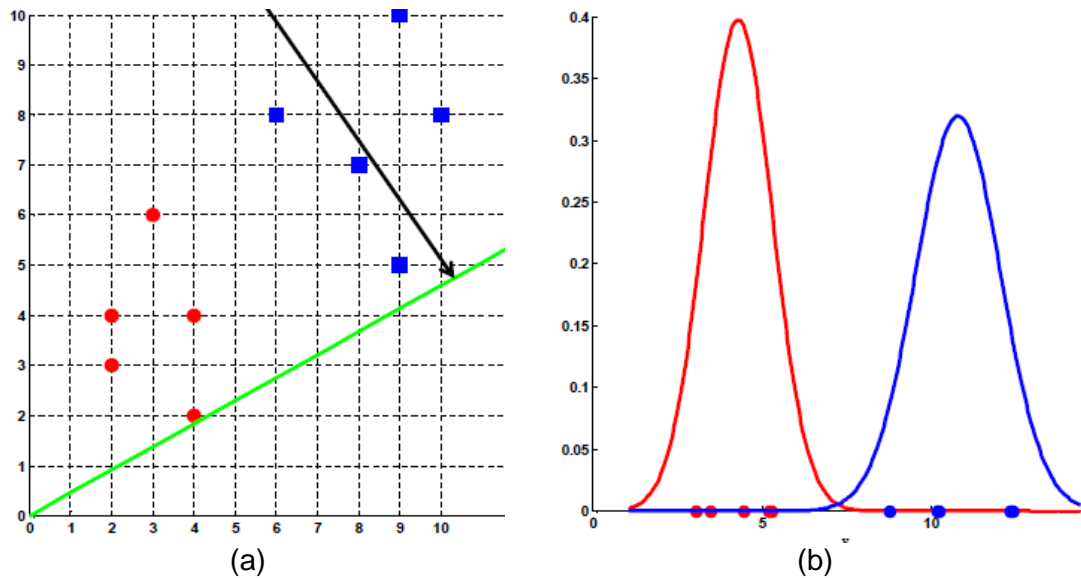


Figura 2.14. Algoritmo LDA usando el máximo auto valor.

Es importante mencionar que la proyección de las características de los elementos sirve para conocer la separabilidad de las categorías, no es importante el rango que ocupen numéricamente sobre el vector de rotación. Así mismo, el eje de proyección no tiene unidades definidas ya que podría ser la combinación de muchas características que no comparten unidades.

2.6. Red neuronal artificial

Una red neuronal artificial es un modelo matemático que emula el funcionamiento de las neuronas biológicas [14]. Está compuesta por unidades de procesamiento que emulan a las neuronas, así como conexiones entre capas que emulan las sinapsis que recogen información de entrada para generar una salida de información útil.

Cada conexión está asociada a un peso, que representa la información utilizada por las neuronas para resolver un problema específico. Cada uno de estos procesadores o neuronas suma las entradas ponderadas y su resultado pasa a través de una función no lineal conocida como función de activación.

Las redes neuronales constan de los siguientes elementos:

- Entradas: pueden ser números enteros, binarios o bipolares.
- Pesos sinápticos: pesos adaptivos que contienen información aprendida.
- Regla de propagación: La regla de propagación determina el potencial resultante de la interacción de las neuronas con las neuronas vecinas.
- Función de activación: función de salida de las neuronas, pueden ser funciones identidad, sigmoide, etc.
- Capa de salida: Etapa de salida proporciona el valor de salida de la neurona, en base al estado de activación.

Entre las principales características de las redes neuronales se encuentran: aprenden a través de ejemplos, son adaptables, capaces de generalizar, tolerantes a fallas y de fácil implementación. Dada su versatilidad se suelen aplicar para el reconocimiento de patrones, pronóstico, optimización, mapeo de características, entre otros.

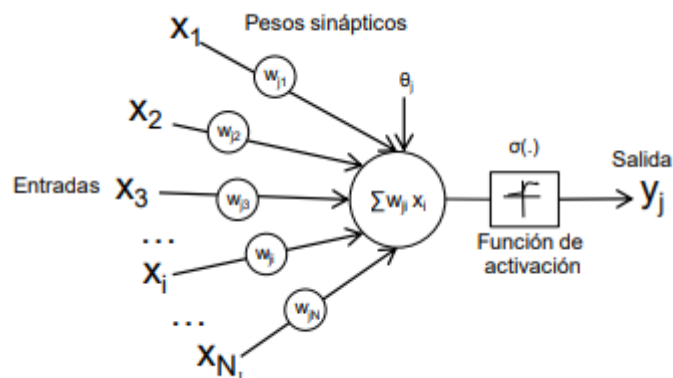


Figura 2.15. Diagrama de una red neuronal artificial básica.

Se muestra en la Figura 2.12 el modelo de red neuronal más simple, que consta de una capa de entrada, que se conecta a una etapa de procesamiento, emulando las conexiones sinápticas, donde se recoge la información de las neuronas y se obtiene un nivel de potencial. Luego, el potencial es procesado por la función de activación que da lugar a la salida de la red.

Definamos a la función de activación como $h(b)$, donde b representan a las entradas a la red neuronal. Las principales funciones de activación utilizadas en redes neuronales artificiales son presentadas a continuación:

Escalón unitario:

$$h(b) = \begin{cases} 1 & b \geq 0 \\ 0 & b < 0 \end{cases} \quad (24)$$

Lineal:

$$h(b) = b \quad (25)$$

Sigmoidea:

$$h(b) = \frac{1}{1 + e^{-b}} \quad (26)$$

Tangente hiperbólica:

$$h(b) = \frac{1 - e^{-b}}{1 + e^{-b}} \quad (27)$$

Cuando los algoritmos de aprendizaje requieren que la función de activación sea derivable se suelen emplear la función de sigmoidea o tangente hiperbólica. La salida de una neurona artificial (al igual que las entradas) puede ser binaria (digital) o continua (analógica), dependiendo del modelo y de la aplicación. Por ejemplo, para tareas de clasificación se emplearían salidas binarias, mientras que en un problema de ajuste funcional de una aplicación multivariable continua, se emplearían salidas continuas dentro de un cierto intervalo [15].

El método de aprendizaje básico para las redes neuronales artificiales es el algoritmo de retropropagación de errores (*backpropagation*), este algoritmo es un método de optimización por el descenso de gradiente de una función de error, con el cual se busca minimizar el error cuadrático medio [15]. Consta de 3 fases: fase de cómputo hacia adelante utilizando el patrón de entrada a la red, cálculo del error medio y retropropagación y ajuste de pesos sinápticos.

La importancia de este proceso se debe que a medida que se entrena la red, las neuronas aprenden a reconocer características de la entrada. Después del entrenamiento, cuando se le presente un patrón desconocido de entrada que contenga ruido, distorsión o que esté incompleto, las neuronas responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas hayan aprendido a reconocer durante su entrenamiento [15].

2.7. Reconocimiento de patrones

La búsqueda de patrones en los datos ha sido fundamental a lo largo del tiempo. Por ejemplo, las extensas observaciones astronómicas de Tycho Brahe en el siglo XVI permitieron a Johannes Kepler descubrir las leyes empíricas del movimiento planetario, que a su vez proporcionaron un trampolín para el desarrollo de la mecánica clásica [16]. El campo del reconocimiento de patrones se relaciona con el descubrimiento automático de regularidades en los datos mediante el uso de algoritmos informáticos y con el uso de estas regularidades realizar acciones tales como clasificar los datos en diferentes categorías.

Un patrón podría ser una imagen de huella digital, una palabra escrita a mano, un rostro humano o una señal de radar. Dado un patrón, su reconocimiento o clasificación puede consistir en una de las siguientes dos tareas [17]:

- 1) Clasificación supervisada en la que el patrón de entrada se identifica como un miembro de una clase predefinida,
- 2) Clasificación no supervisada en la que el patrón se asigna a un modelo de clase desconocido.

El problema de reconocimiento se plantea como una tarea de clasificación o categorización, donde las clases son definidas por el diseñador del sistema (en la clasificación supervisada) o se aprenden según la similitud de los patrones (en la clasificación no supervisada).

Para la mayoría de las aplicaciones prácticas, las variables de entrada originales normalmente se procesan previamente para transformarlas en un nuevo espacio de variables donde, se espera, el problema de reconocimiento de patrones será más fácil de resolver. Esta etapa de pre-procesamiento a veces también se denomina extracción de características. Una vez pre-procesada la información, las cuatro técnicas más utilizadas para el reconocimiento de patrones según [17] son:

- 1) Coincidencia de plantillas,
- 2) Clasificación estadística,
- 3) Coincidencia sintáctica o estructural, y
- 4) Redes neuronales.

2.8. Coherencia

Antes de empezar con la implementación de los estimadores es necesaria la definición de coherencia. La coherencia puede ser definida como el grado de similitud entre dos conjuntos de datos mediante el siguiente coeficiente de correlación:

$$co(x, y) = \frac{\overline{I_1(x, y) \cdot conj(I_2(x, y))}}{\sqrt{\overline{I_1(x, y) \cdot conj(I_1(x, y))} \cdot \overline{I_2(x, y) \cdot conj(I_2(x, y))}}} \quad (28)$$

Definimos que el operador \overline{A} devuelve el promedio de A en una ventana espacial.

El valor de c está definido en el rango de 0 a 1 y puede ser modelado de la siguiente manera:

$$co = co_{scene} \cdot co_N \quad (29)$$

Siendo co_{scene} el aporte de coherencia generado por la zona alumbrada y co_N la coherencia generada por el ruido y los errores de aproximación del procesador.

2.9. Teorema del límite central

El teorema del límite central o teorema central del límite indica que, si S_n es la sumatoria de n variables aleatorias independientes de varianzas no nulas pero si finitas, entonces la distribución de S_n será una función de densidad de probabilidad del tipo gaussiana. Este teorema se puede garantizar siempre y cuando n sea lo suficientemente grande.

Por otro lado, se denotan las fases de retorno $\Psi_1, \Psi_2, \dots, \Psi_n$ que corresponden a un mismo pixel a través del tiempo. Bien es sabido que cada pixel representa una porción de superficie que contiene una cantidad enorme de elementos dispersores en las que cada uno aporta en amplitud y fase a la señal de retorno, es así que, debido al ruido o condiciones atmosféricas las fases $\Psi_1, \Psi_2, \dots, \Psi_n$ se considerarán como estadísticamente independientes. Entonces, definamos a $\hat{\Psi}$ como la suma de los procesos aleatorios $\Psi_1, \Psi_2, \dots, \Psi_n$:

$$\hat{\Psi} = \Psi_1 + \Psi_2 + \Psi_3 + \dots + \Psi_n \quad (30)$$

Definamos la media de $\hat{\Psi}$ como:

$$\overline{\hat{\Psi}} = \overline{\Psi_1} + \overline{\Psi_2} + \overline{\Psi_3} + \dots + \overline{\Psi_n} \quad (31)$$

Siendo $\overline{\Psi_1}, \overline{\Psi_2}, \overline{\Psi_3}, \dots, \overline{\Psi_n}$ las medias de $\Psi_1, \Psi_2, \dots, \Psi_n$ respectivamente. La varianza del $\hat{\Psi}$ queda definida por:

$$E[(\hat{\Psi} - \bar{\Psi})^2] = \sigma_{\hat{\Psi}}^2 \quad (32)$$

Resuelta por [20] se obtiene que:

$$\sigma_{\hat{\Psi}}^2 = \sigma_{\Psi}^2/n \quad (33)$$

Por lo tanto, la varianza en la información se verá reducida n veces.

2.10. Teledetección

La teledetección o percepción remota se define en [18] como la medición de las propiedades de los objetos en la superficie de la tierra utilizando datos adquiridos de, sensores, aeronaves y satélites. Por lo tanto, es un intento de medir algo a distancia.

Como no se está en contacto directo con el objeto de interés, las mediciones se hacen indirectamente con señales propagadas de algún tipo, por ejemplo, ópticas, acústicas o electromagnéticas.

Los sistemas de teledetección, especialmente los desplegados en radares, proporcionan una visión repetitiva y coherente de la Tierra que es invaluable para monitorear los cambios a corto y largo plazo y el impacto en las actividades humanas. Algunas de las aplicaciones importantes presentadas también en [18] de la tecnología de teledetección son:

- 1) Evaluación y seguimiento ambiental (crecimiento urbano, residuos peligrosos).
- 2) Detección y monitoreo del cambio global (agotamiento del ozono atmosférico, deforestación, calentamiento global)
- 3) Agricultura (condición del cultivo, predicción del rendimiento, erosión del suelo)
- 4) Exploración de recursos no renovables (minerales, petróleo, gas natural)
- 5) Recursos naturales renovables (humedales, suelos, bosques, océanos)
- 6) Meteorología (dinámica de la atmósfera, predicción del tiempo)
- 7) Mapeo y caracterización geodinámica (topografía, uso del suelo, ingeniería civil)
- 8) Vigilancia y reconocimiento militar (política estratégica, evaluación táctica)
- 9) Medios de comunicación (ilustraciones, análisis).


Para satisfacer las necesidades de las diferentes aplicaciones de datos, se han desarrollado muchos sistemas de teledetección, que ofrecen una amplia gama de parámetros espaciales, espectrales y temporales. Algunas aplicaciones pueden requerir una cobertura frecuente y repetitiva con una resolución espacial relativamente baja (meteorología). Otras pueden desear la resolución espacial más alta posible con

cobertura de repetición con poca frecuencia (mapeo); mientras que algunos usuarios necesitan tanto una resolución espacial alta como una cobertura frecuente, además de la entrega rápida de imágenes (vigilancia militar, monitoreo de suelos).

2.11. Detección de movimiento en radares SAR

Los radares de apertura sintética suelen ser utilizados principalmente para la generación de imágenes de radar. Una de las condiciones necesarias para una buena calidad de señal SAR es que los elementos sobre los cuales la onda emitida sea reflejada nuevamente hacia el radar tengan fase cuasi constante. Sin embargo, hay movimientos que el radar de apertura sintética puede detectar, siempre y cuando estos sean bastante lentos. Esta característica de los SAR ha hecho que surjan aplicaciones de detección de movimiento de masa terrestre, glaciares, volcanes, y demás fenómenos con movimientos lentos.

Asumamos una disposición de radar presentado en la figura X, donde el radar apunta a una escarpa o ladera. El radar, adquiere información cada T segundos, en donde se genera una matriz con información acerca de la amplitud y fase de toda la región alumbrada. Para observar cómo es que el movimiento es observado por el radar, evaluaremos solo el comportamiento de la señal para el punto p durante un tiempo de adquisición de señal de 3.5 min.




Como se mencionó previamente, cada vez que el radar emita señal se recibe una matriz de información con la siguiente forma:


$$g_{(r,\theta)}^k = |g_{(r,\theta)}^k| e^{j(4\pi f t + \gamma_{(r,\theta)}^k)} \quad (33)$$

Donde r y θ son las coordenadas en rango y azimut respectivamente, k es el instante de tiempo donde se realiza la medición y γ es el cambio de fase originado por el objeto retrodispersor. En caso γ cambie, se asume que hubo un cambio de la posición del objeto en medición para la coordenada correspondiente.


Para el punto en estudio p se presenta en la Figura 2.16 la fase $\gamma_{(r_p, \theta_p)}^k$ para todos los instantes k hasta un tiempo de 3.5 min de adquisición. La Figura 2.16a presenta un escenario ideal, sin ruido y sin movimiento, la Figura 2.16b un escenario sin movimiento y con ruido y finalmente la Figura 2.16c un escenario con movimiento y ruido.



(a)



(b)



(c)

Figura 2.16. Fases medidas por el radar para un punto en específico y su comportamiento a través del tiempo (a) Sin movimiento de objeto y sin ruido (b) Sin movimiento del objeto y con ruido (c) Señal ruidosa correspondiente al movimiento de un objetivo.

La variación de fase $\Delta\gamma$ desde la primera adquisición hasta la última adquisición es proporcional al movimiento en ese intervalo de tiempo y está caracterizado por la siguiente igualdad:

$$mov = \Delta y \frac{\lambda}{4\pi} \quad (33)$$

2.12. Generación de stack de datos

Para el procesamiento de señal que se requiere realizar en este libro de tesis se necesita conocer el concepto de *stack* de datos y como está organizada la señal dentro de ella. Supongamos que para instante de medición k se tiene una matriz de datos que contiene la amplitud y fase de todos los puntos M en azimut y los N puntos en rango adquiridos por una vuelta de radar (SAR con trayectoria tipo arco), si se apila una nueva matriz de datos tras la anterior para todo el tiempo de adquisición se tendrá una *stack* de M puntos en azimut por N puntos en rango y L adquisiciones a través del tiempo en donde cada pixel tendrá información acerca de la amplitud y fase de la región censada al momento correspondiente. En la Figura 2.17 se muestra un *stack* de información y su interpretación.




Figura 2.17. Stack de datos.

2.13. Deslizamientos

Los deslizamientos son movimientos de rocas, suelos, materiales artificiales o una combinación de los mismos, que se producen a lo largo de una superficie a favor de la pendiente [19]. Es importante saber cómo se mueven los materiales que componen una zona propensa a deslizarse y proponer, según ello, medidas de prevención que permitan su control.

Estos tipos de movimiento de suelos se clasifican principalmente en seis tipos: caída, vuelco, deslizamientos rotacionales y traslacionales, extensiones laterales, flujos y

reptaciones. Cada uno de ellos a su vez puede subdividirse por los materiales que la componen (escombros, rocas duras, zonas con vegetación).

Para determinar la amenaza a la cual se encuentra una zona geográfica, se consideran generalmente cinco factores intrínsecos: pendiente, textura de suelo, cobertura, geomorfología y geología. Se define brevemente cada uno de estos factores a continuación:

- **Pendiente o escarpa:** conocida también como componente de relieve. Grado de inclinación del terreno o gradiente, expresado generalmente en porcentaje o grados. Su valor está directamente relacionado con la estabilidad de una ladera. Se presenta la Tabla 2.1 con los porcentajes propuestos por la Organización de las Naciones Unidas para la Agricultura y la Alimentación para la clasificación de suelos.

Tabla 2.1. Clasificación de suelos.

Descripción	Inclinación (%)
Plano	0–0,2
Nivel	0,2–0,5
Cercano al nivel	0,5–1,0
Muy ligeramente inclinado	1,0–2,0
Ligeramente inclinado	2–5
Inclinado	5–10
Fuertemente inclinado	10–15
Moderadamente escarpado	15–30
Escarpado	30–60
Muy escarpado	> 60

- **Textura de suelo:** la textura del suelo se refiere a la proporción relativa de las clases de tamaño de partícula (o separaciones de suelo, o fracciones) en un volumen de suelo dado y se describe como una clase textural de suelo. En la Tabla 2.2 se presenta las texturas de suelo.

Tabla 2.2. Textura de suelo.

Clases texturales del suelo	~% Arcilla
Arena	< 5
Areno francoso	< 12
Franco arenoso	< 10
Franco limoso (pobre en arcilla)	< 10
Franco limoso (rico en arcilla)	10–27
Franco arcillo arenoso	20–35

Arcillo arenoso (granuloso)	35–55
Franco arcilloso	25–40
Arcilloso	40–60
Arcillo limoso	40–60
Arcilla pesada	>60

- Cobertura: La cobertura de suelo describe el material físico de la Tierra, de esta manera, la definición está relacionada estrechamente a las clases de cobertura con sus características físicas. Algunos ejemplos de clases de cobertura de suelo son: bosque, cuerpos de agua y suelos desnudos.
- Geomorfología: la composición y estructura de la tierra. Este factor da cuenta de los tipos de rocas y su relación con la inestabilidad presente en el área de estudio.
- Geología: origen, formación y evolución de la Tierra, los materiales que la componen y su estructura.

CAPITULO III METODOLOGÍA

En este capítulo se explica el modelo de adquisición de señales y el desarrollo del método.

3.1. Tipo y nivel de investigación

El presente trabajo de tesis propone una investigación aplicada ya que tiene un fin práctico inmediato para su aplicación en la caracterización de zonas con ocurrencia de actividad geodinámica utilizando medidas estadísticas aplicadas a señales de radar de banda X para obtener la cantidad de movimientos en una determinada región geográfica. El análisis empleado es de tipo cuantitativo, ya que con mediciones de desplazamiento de superficie terrestre se pretende caracterizar la geodinámica de un área.

El nivel de la investigación es de tipo correlacional. La investigación relaciona las características geomorfológicas y climatológicas de una zona determinada y la peligrosidad de un deslizamiento, asociándolas con una relación de causa y efecto con utilizando señales de radar de banda X.

3.2. Diagrama de bloques del desarrollo del trabajo de tesis

El método utilizado en este trabajo de tesis se dividió en cuatro secciones: inicio de la investigación, adquisición y pre-procesamiento, procesamiento y análisis de resultados. Cada sección cuenta con diferentes etapas que serán descritas brevemente en este subcapítulo. En la Figura 3.1 se muestra el diagrama de bloques completo y las etapas que implican cada una de las secciones. De acuerdo con los objetivos específicos de este trabajo de tesis, se muestra en el diagrama de bloques las secciones donde se realiza el estudio de cada uno de ellos, siendo coloreados de color rojo los bloques involucrados con el primer objetivo específico. De forma similar, se encuentra coloreado de color azul el bloque que involucra el estudio del segundo objetivo específico, y el bloque coloreado de color verde involucra el estudio del tercer objetivo específico. El estudio y análisis del objetivo general se realiza en la última sección del diagrama.

En la primera sección, encontramos el inicio de la investigación. En esta etapa se tomaron dos decisiones importantes, la primera relacionada al periodo de análisis en el que se realizará el estudio de detección de movimientos de suelo, siendo la más trascendente la época de inicio de lluvias. La siguiente decisión fue la elección del sensor y el estudio de sus especificaciones técnicas, en este caso el radar SENTIR-GEO. Conocer sus especificaciones y limitaciones técnicas es importante para la elección del método de cálculo de movimientos a utilizar posteriormente.

En segunda sección se encuentra la etapa de adquisición de datos y pre-procesamiento. Se realizaron dos adquisiciones de datos: se recolectó información acerca de las precipitaciones en la zona de estudio durante la duración del experimento y se adquirió señal de radar utilizando el radar SENTIR-GEO. La información de precipitaciones no necesita ser pre-procesada, sin embargo, la señal proveniente del radar necesita de un pre-procesamiento y posterior procesamiento para generar la información deseada para este trabajo de tesis. El radar provee una matriz de datos cada segundo, sin embargo, esta matriz necesita ser filtrada, enfocada y organizada de tal forma que, para cada revolución del radar sobre su eje, se tenga una matriz de datos de hasta un kilómetro de alcance para todos los ángulos del azimut. Luego de este proceso, la información generada para cada revolución se coloca en un arreglo de matrices a la cual se conoce como *stack* de datos. El *stack* será procesado para el cálculo de movimientos, sin embargo, existe un parámetro a calibrar en esta etapa y es el tiempo de integración de datos o cantidad de matrices que tendrá el *stack*. Como este tiempo de integración de datos está bastante ligado a la complejidad del estimador de movimientos utilizado y la carga computacional que genera, se considera una consecuencia de la aplicación del método y su estudio será analizado en el capítulo IV.

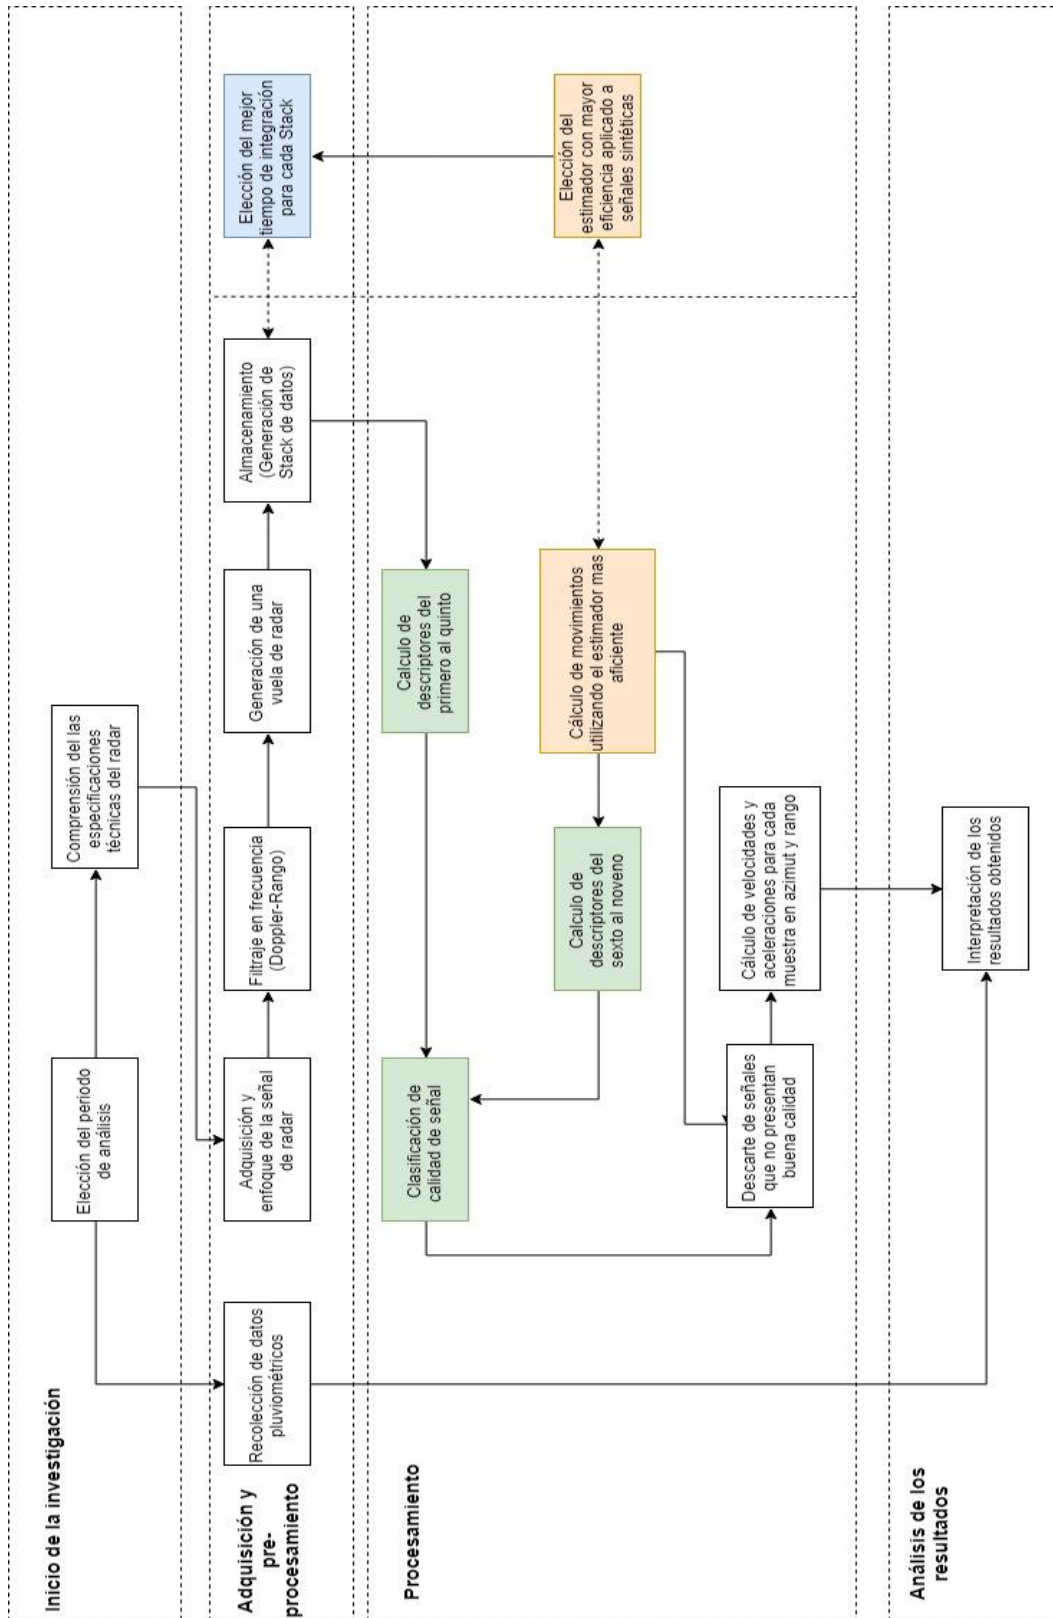


Figura 3.1. Diagrama de bloques del desarrollo de la investigación.

En la tercera sección, se encuentra el procesamiento de la señal de radar agrupada en *stacks* de datos. El proceso es el siguiente: aplicación del estimador de movimiento, cálculo de descriptores de calidad de señal, clasificación de calidad de señal según los descriptores calculados, eliminación de movimientos generados por señales con mala calidad y cálculo de velocidades y aceleraciones para cada movimiento detectado. Para la etapa del cálculo de movimiento, primero se realizó la implementación de tres estimadores de movimiento para decidir cuál de ellos presentaba un mejor desempeño con las condiciones de resolución, potencia y cantidad de ruido que el radar SENTIR-GEO proveía. Este estudio realizó sobre datos sintéticos y su desarrollo se encuentra en el subcapítulo **3.5.6.** donde se muestra su respectivo diagrama de bloques. El cálculo de descriptores se realiza antes del cálculo de movimientos y después del cálculo de movimientos. La cantidad de descriptores utilizados fueron nueve y la demostración de la capacidad que tienen para representar las dos categorías a clasificar (mala calidad de señal y buena calidad de señal) es hecha utilizando el algoritmo LDA. Posteriormente para realizar la clasificación se utiliza una red neuronal artificial de clasificación, la cual se entrena con las mismas señales sintéticas utilizadas para la elección del mejor estimador.

En la última sección, se realiza el análisis de los movimientos, velocidades y aceleraciones ocurridas durante el experimento y su relación con los datos pluviométricos adquiridos. En esta sección se entregan reportes visuales superpuestos al mapa de la zona en estudio para realizar una interpretación más sencilla.

3.3. Periodo de análisis

El lugar elegido para instalar el radar para las campañas fue el distrito de Xerém, estado de Río de Janeiro, Brasil, con coordenadas 22°34'9.09"S, 43°18'47.80"W a 32 m sobre el nivel del mar. El lugar escogido tiene una buena vista en línea directa a la región con riesgo potencial a presentar deslizamientos.

En la Figura 3.2 se muestra un mapa con una vista general de la ubicación del radar con respecto a la zona elegida para monitorear.




Figura 3.2. Vista superior de la zona de alcance del radar.

En la Figura 3.3 se muestra el radar apuntando a la pendiente desde una vista frontal.



Figura 3.3. Vista directa del radar hacia la pendiente.

La campaña de adquisición de señales de radar fue planeada para ser realizada durante la época de lluvias. El periodo escogido fue desde el 15 al 22 de febrero del

2016. De acuerdo con lo verificado en campo y con los datos pluviométricos, en la zona bajo estudio ocurrieron lluvias casi todos los días, siendo que el día 16 de febrero del 2016 hubo una lluvia intensa con volumen acumulado de 70 mm en 2 h.

En esta campaña hubo interrupciones en el monitoreo debido a falta de energía y también debido a problemas de red con el radar. Las interrupciones no comprometen el análisis ya que fueron obtenidas 4 series de datos que serán identificadas como “expXerem_20160215”, “expXerem_20160216”, “expXerem_20160216a” y “expXerem_20160219”. En la

Tabla 3.1 se muestra el resumen con el cronograma de la adquisición de datos.

Tabla 3.1 Cronograma de adquisición de la serie expXerem_20151209

Fecha	15 de febrero del 2016												16 de febrero del 2016																	
Hora	2	4	6	8	10	12	14	16	18	20	22	24	2	4	6	8	10	12	14	16	18	20	22	24						
Oper.	Embarque y montaje del radar												+	+	+	+	+	+	+	-	+	+	+	-	+	+	+			
Serie													expXerem_20160215						expXerem_20160216a						expXerem_20160216					

Fecha	17 de febrero del 2016												18 de febrero del 2016											
Hora	2	4	6	8	10	12	14	16	18	20	22	24	2	4	6	8	10	12	14	16	18	20	22	24
Oper.	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	/	/	/
Serie	expXerem_20160216																							

Fecha	19 de febrero del 2016												20 de febrero del 2016											
Hora	2	4	6	8	10	12	14	16	18	20	22	24	2	4	6	8	10	12	14	16	18	20	22	24
Oper.	/	/	/	/	/	/	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
Serie	expXerem_20160219																							

Fecha	21 de febrero del 2016												22 de febrero del 2016											
Hora	2	4	6	8	10	12	14	16	18	20	22	24	2	4	6	8	10	12	14	16	18	20	22	24
Oper.	+	+	+	+	+	+	+	-	-	-	-	-	-	-	-	-	-	-	Fin de adquisición. Embarque de radar					
Serie	expXerem_20160219																							

“+”: Funcionamiento correcto del radar
“-”: Falta de energía
“/”: Error del radar

3.4. Fuentes de información e instrumentos utilizados

A continuación, se listan las distintas fuentes de información y los instrumentos que se requirieron para la aplicación del método propuesto por este libro de tesis.

3.4.1. Radar SENTIR-GEO

El SENTIR-GEO es un radar compacto y de corto alcance con la capacidad de detectar movimientos de suelo. Es un radar de fácil transporte y ensamblaje, preparado para la intemperie. Este radar consta de una batería que le permite una autonomía de 4 horas.

El SENTIR-GEO opera en la banda X con una longitud de onda λ de 0.031 m. Tiene 3 km de alcance con una resolución en rango de 3.125 m con un pulso de duración 50 us. El pulso es de frecuencia modulada linealmente (CHIRP).

El radar cuenta con una antena transmisora (Tx) y dos antenas receptoras (Rx). La disposición de las antenas se muestra en la Figura 3.4. La antena más cercana a Tx recibirá el nombre de antena interna y la antena más lejana será la antena externa. Para este estudio solo se utilizará la onda correspondiente al canal de recepción Rx de la antena interna, mientras que la señal de la antena externa será descartada ya que la aplicación no lo requiere.




Figura 3.4. Disposición geométrica de las antenas del radar y del objetivo.

El radar tiene un mecanismo de giro con velocidad angular ω de $\pi/2$ rad/s. El radio r de la trayectoria circular y el ancho de haz θ_{real} en azimut es de 112° , para la antena real. Como se observa en la Figura 3.4, la geometría del escaneo del radar es de tipo circular y la apertura sintética del radar con e igual a 0.26 m es de 1.8° .

Generalmente, los radares terrestres trabajan con una resolución de 0.5° en azimut. Este radar opera con una resolución menor, por ello, solo consigue resolver sin

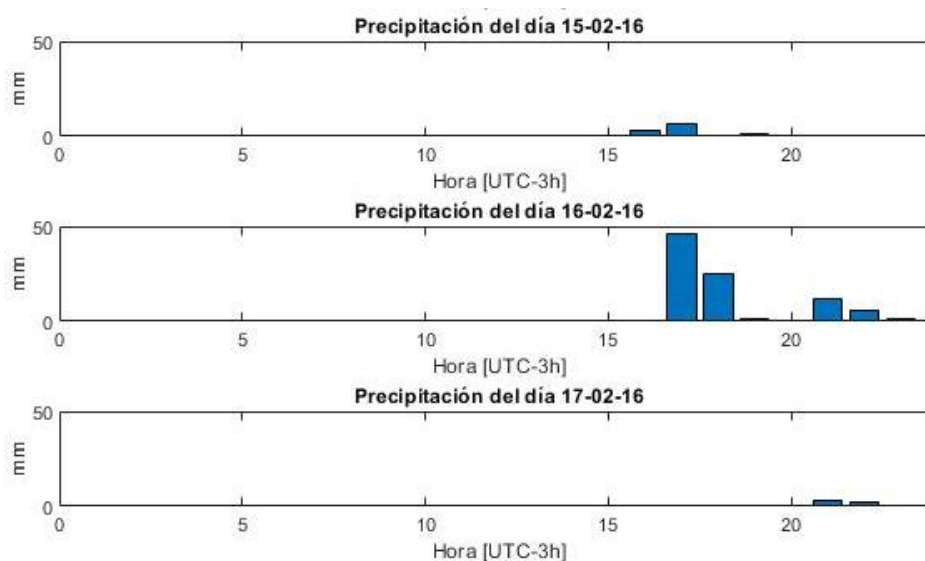
ambigüedades movimientos de zonas menores a 1 km de distancia. Con estas especificaciones el radar es capaz de detectar movimientos de desplazamientos de suelo en el orden de los milímetros. La Tabla 3.2 tiene un resumen de las especificaciones del radar SENTIR-GEO.

Tabla 3.2. Resumen de especificaciones del radar.

Parámetro	Descripción
Peso total	20 kg
Potencia de transmisión	30 w
Frecuencia de operación	9.55 GHz (banda X)
Modulación	CHIRP
Resolución en rango	3.125 m (48 MHz)
Resolución en azimuth	1.8°
Polarización	VV
Geometría del escaneo	Angular
Ancho de rayo en elevación	27°
Número de antenas	3 (1 transmisor y 2 receptores)
Comunicación	Ethernet
Procesamiento	En tiempo real

3.4.2. Datos pluviométricos de INMET

Los datos pluviométricos utilizados para correlacionar los movimientos de masa terrestre fueron obtenidos por el Instituto Nacional de Meteorología de Brasil (INMET), en la estación más próxima a Xerém (coordenadas 22° 35'23.3"S y 43° 16'56.0"W) y las mediciones de precipitación en las fechas en las que el radar monitoreó la zona de análisis se muestran en la Figura 3.5.



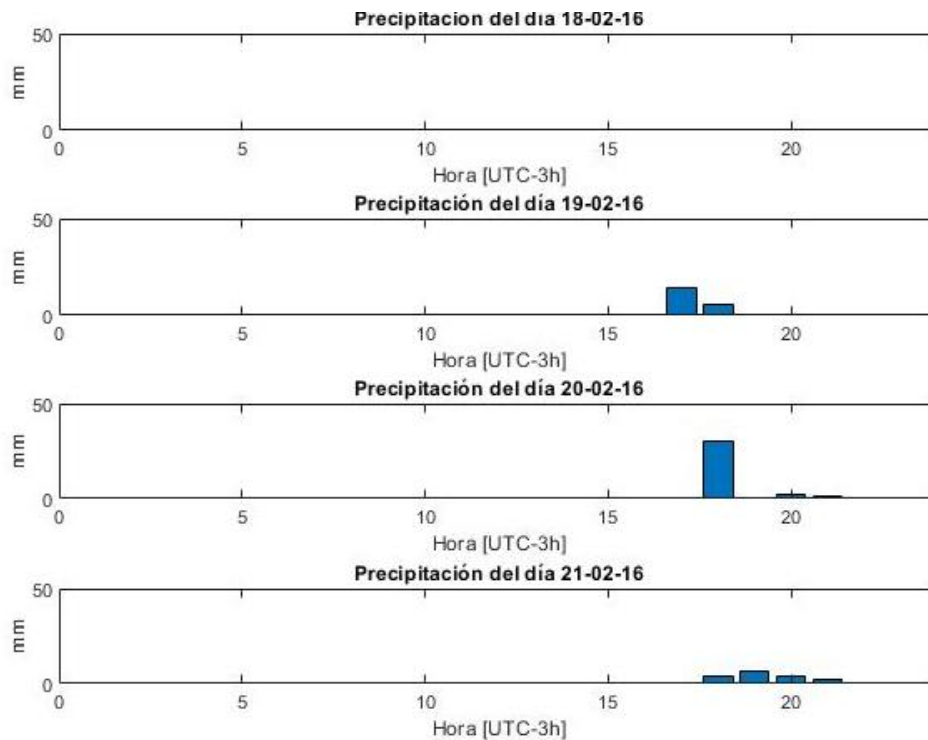


Figura 3.5. Precipitaciones en los días de adquisición de señal.

3.4.3. Técnica de Recolección de Datos

Como se mencionó anteriormente, el radar SENTIR-GEO es un radar de montaje en el suelo con un giro preciso de $\pi/2$ rad/s, como consecuencia, los datos brutos presentan invariancia espacial [21].

El escaneo del radar es de 15 revoluciones por minuto, es decir, da una vuelta entera sobre su eje cada 4 s. La matriz de datos brutos que se genera cada segundo a partir de la señal recibida en la antena interna Rx, tiene una dimensión de 1024 pixeles en rango por 8192 pixeles en azimuth (especificaciones de radar). Los 1024 pixeles corresponden a 3 km de distancia radial, pero los 8192 pixeles en azimuth están compuestos de la siguiente manera: las primeras 5570 muestras representan señal bruta, pero las últimas 2622 son completados con ceros. Este artificio es conocido como *zero-padding* y facilita algunos cálculos que más adelante serán explicados con mayor detalle.

3.5. Desarrollo del trabajo de tesis

Es importante definir la naturaleza de la señal recibida por el radar. Llamaremos $g_{(r,\theta)}^k$ a la matriz de datos que en este caso, tendrá 1024 por 5570 pixeles con información relevante. Haciendo un cambio de coordenadas, para tener un mejor entendimiento de

la señal debido al escaneo circular, se transforma de las coordenadas rectangulares x, y a las coordenadas polares r, θ , y así se llega al siguiente modelo planteado en [10]:

$$g_{(r,\theta)}^k = |g_{(r,\theta)}^k| e^{j(4\pi fr + \sigma_{(r,\theta)}^k + \alpha_{(r,\theta)}^k + n_{(r,\theta)}^k)} \quad (35)$$

Donde f es la frecuencia Doppler recibida por el radar, k es el momento en el que los datos fueron tomados, $\sigma_{(r,\theta)}^k$ es la reflectividad de fase del objeto alumbrado, $\alpha_{(r,\theta)}^k$ es la contribución del efecto de la atmosférica en la fase, $n_{(r,\theta)}^k$ es el ruido en la fase de la señal recibida y $g_{(r,\theta)}^k$ es equivalente al campo eléctrico $E_{(r,\theta)}^k$ recibido por el radar. Se puede observar que $\alpha_{(r,\theta)}^k$ y $n_{(r,\theta)}^k$ pueden ser consideradas como ruido multiplicativo de diversas distribuciones de probabilidad (dependiendo de la homogeneidad o heterogeneidad de la zona alumbrada) que causa errores de detección en los movimientos. Definamos ahora $\Psi_{(r,\theta)}^k$ como la fase total en el momento k , así se tiene:

$$\Psi_{(r,\theta)}^k = 4\pi fr + \sigma_{(r,\theta)}^k + \alpha_{(r,\theta)}^k + n_{(r,\theta)}^k \quad (36)$$

La fase total para cada pixel está “doblada”, es decir, está en el rango de $-\pi$ a π . Por lo tanto, para un pixel en el tiempo pueden existir saltos de fase de 2π , que correspondería a un movimiento de una longitud de onda completa, lo cual no es común en este tipo de aplicaciones. Se muestra en la Figura 3.6 una señal correspondiente a un pixel en el espacio a través del tiempo con problemas de fase doblada.

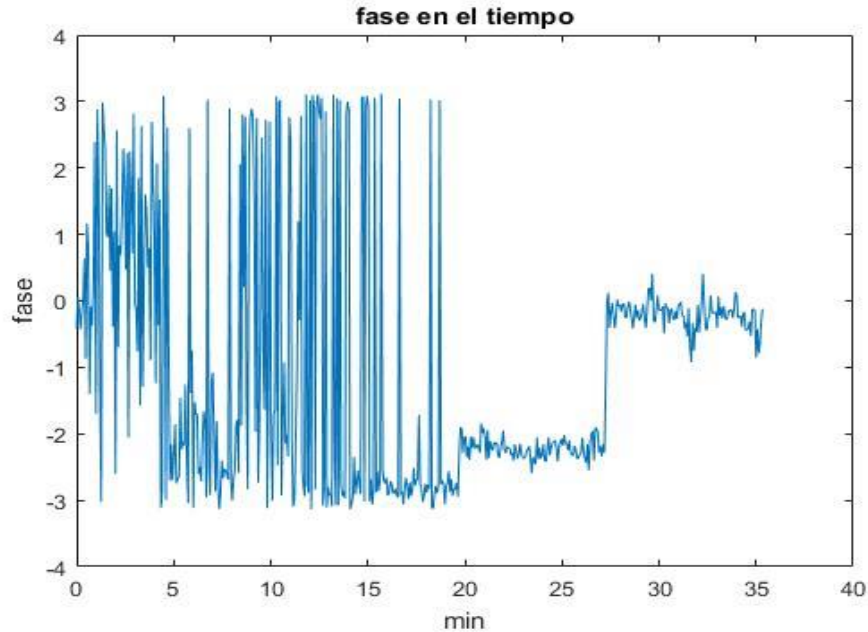




Figura 3.6 Señal con problemas de fase doblada

Analizando la Ecuación (32), el efecto visto en los primeros 15 min de adquisición de señal de la Figura 3.6 es causado las variaciones y perturbaciones de $\sigma_{(r,\theta)}^k$, $\alpha_{(r,\theta)}^k$ y


$n_{(r,\theta)}^k$. Se presenta en la Figura 3.7 histogramas de fases para cuatro regiones aleatorias de la matriz de datos de fase de hasta 1 km de alcance (región A, B, C y D) y diferentes cantidades de muestras acumuladas en el tiempo (En la Figura 3.8 se muestra de forma gráfica que datos fueron utilizados para la composición de los histogramas) para observar la naturaleza de las distorsiones añadidas a la fase de retorno adquirida por el radar. Idealmente, la fase siempre debería ser la misma.




(a)




(b)



(c)



(d)



(e)

Figura 3.7 Histogramas de fase de las regiones A, B, C y D (a) 50 muestras en el tiempo (b) 100 muestras en el tiempo (c) 250 muestras en el tiempo (d) 500 muestras en el tiempo (e) 1000 muestras en el tiempo.

Como se observa, los histogramas muestran la tendencia de la distribución de datos, y en la mayoría de casos se asemeja a una función de densidad de probabilidad gaussiana.




Figura 3.8. Datos del stack utilizados para la generación de los histogramas de fase.

3.5.1. Pre procesamiento

Antes del cálculo de movimiento de masa terrestre existen tres grandes problemas, el primero es que la señal distorsionada por el ruido, la segunda es que existen problemas de fase doblada donde las medidas estadísticas tienen mucha varianza y hacen difícil la estimación del movimiento adecuado y el tercer problema es que la matriz de datos brutos tiene en su información objetos que se están moviendo rápidamente y que no son de interés. Se presume que los cálculos propuestos por esta metodología funcionan sin ambigüedades, por lo que los movimientos calculados durante el periodo de integración son menores a una longitud de onda.

3.5.1.1. Filtraje en la frecuencia

Para cada segundo de información se dispone de una matriz de 1024 por 8192 píxeles, como se mostró en el modelo, la matriz es de naturaleza compleja y se encuentra en el dominio del tiempo. El primer paso a realizar para eliminar los movimientos rápidos de la adquisición, es tener la matriz de datos en el dominio del Doppler-Rango, esto se consigue realizando una transformada de Fourier en el sentido azimutal. Es por ello que la matriz efectiva de datos tiene 5570 muestras para cada segundo de adquisición, pero el radar realiza un *zero-padding* completando con ceros hasta tener una longitud igual al número de potencia de dos más cercano para poder realizar correctamente la transformada rápida de Fourier.

Para filtrar los movimientos correspondientes a velocidades muy grandes, nos quedamos con los 256 píxeles centrales de la matriz Doppler-Rango (el píxel central tiene la información de la componente DC de la trama). El precio a pagar por la obtención de la información de los movimientos lentos en el terreno de estudio, es la pérdida de resolución espacial.

Finalmente, se realiza una transformada de Fourier inversa en el sentido azimutal a la matriz y volvemos al dominio Azimut-Rango con una matriz de dimensión 256 por 256 píxeles con la información de los movimientos muy lentos del terreno en estudio.

3.5.1.2. Composición de una vuelta de radar

Cada segundo, el radar hace un escaneo de 180° y rota a razón de $\pi/2$ rad/s, por lo que hay que componer una matriz de una vuelta completa después de 4 s de adquisición. Como se mencionó anteriormente, la matriz, en el sentido azimutal tiene un *zero-padding* de aproximadamente 32% de su longitud total, de las 256 muestras que quedaron en el azimut después del filtraje en la frecuencia, retiramos las últimas 80 muestras. En la Figura 3.9 se muestra el proceso de retirar las muestras debido al *zero-padding*.






Figura 3.9. Matriz de datos correspondiente a un segundo de escaneo (a) Con *zero-padding* (b) Sin *zero-padding*.

El siguiente paso en la composición de la matriz, es la selección de datos no redundantes, que en este caso son el 50% de datos centrales de la matriz, puesto que el escaneo es de 180° y el giro por segundo es de $90^\circ/\text{s}$ existe información redundante que no es de utilidad. Luego de realizar este proceso, se procede a repetir los pasos anteriores para los siguientes 3 segundos, acumulando 4 matrices en total, se colocan una a continuación de la otra, obteniendo así una matriz de datos de 256 pixeles en rango y 350 pixeles en azimut. En la Figura 3.10 se muestra el proceso de selección de información no redundante y la composición de la matriz de una vuelta entera de escaneo.





(c)

Figura 3.10 Composición de matriz de una vuelta entera (a) Matriz sin *zero-padding* correspondiente a un segundo de adquisición (b) 50% de datos centrales de un segundo de adquisición (c) Colección de 4 adquisiciones no redundantes que corresponden a una vuelta entera de radar.

Para tener una comprensión más visual de la composición de una vuelta de información proporcionada por el radar, se muestra en la Figura 3.11 el proceso de adquisición y el tamaño de las matrices que se tiene en cada etapa. El proceso es explicado a continuación:

- a) Primer paso: Adquirir la matriz de datos que el radar proporciona cada segundo con tamaño 8192 en azimut por 1024 en rango. Esta información corresponde a 180° en azimut y 4 kilómetros de alcance.
- b) Segundo paso: Filtrar las velocidades que el radar mide para cada posición en rango, por lo que se pierde resolución en azimut, originando una matriz de datos de 256 pixeles en azimut y 1024 pixeles en rango. Esta información corresponde a 180° en azimut y 4 kilómetros de alcance.
- c) Tercer paso: Eliminación de muestras de alcances mayores a 1 kilómetro, originando una matriz de datos de 256 pixeles en azimut y 256 pixeles en rango. Esta información corresponde a 180° en azimut y 1 kilómetro de alcance.
- d) Cuarto paso: Eliminar las muestras en azimut que solo contienen ceros para todas las muestras en rango debido al *zero-padding* que realiza el radar. Se obtiene una matriz de 176 pixeles en azimut y 256 en rango. Esta información corresponde a 180° en azimut y 1 kilómetro de alcance.

- e) Quinto paso: Conservar solo las muestras centrales en azimut y todos los rangos. Se obtiene una matriz de datos con 88 pixeles en azimut y 256 pixeles en rango. Esta información corresponde a 90° en azimut y 1 kilómetro de alcance.
- f) Sexto paso: Realizar los pasos a, b, c, d y e para cada cuadrante. Esto origina cuatro matrices de 88 pixeles en azimut y 256 pixeles en rango. Cada una con información de 90° en azimut y un kilómetro de alcance.
- g) Séptimo paso: Organizar las cuatro matrices correspondientes a cada cuadrante para obtener una vuelta completa con información sobre los 360° en azimut y un kilómetro de alcance. En esta etapa se tiene una matriz de 352 pixeles en azimut y 256 pixeles en rango.

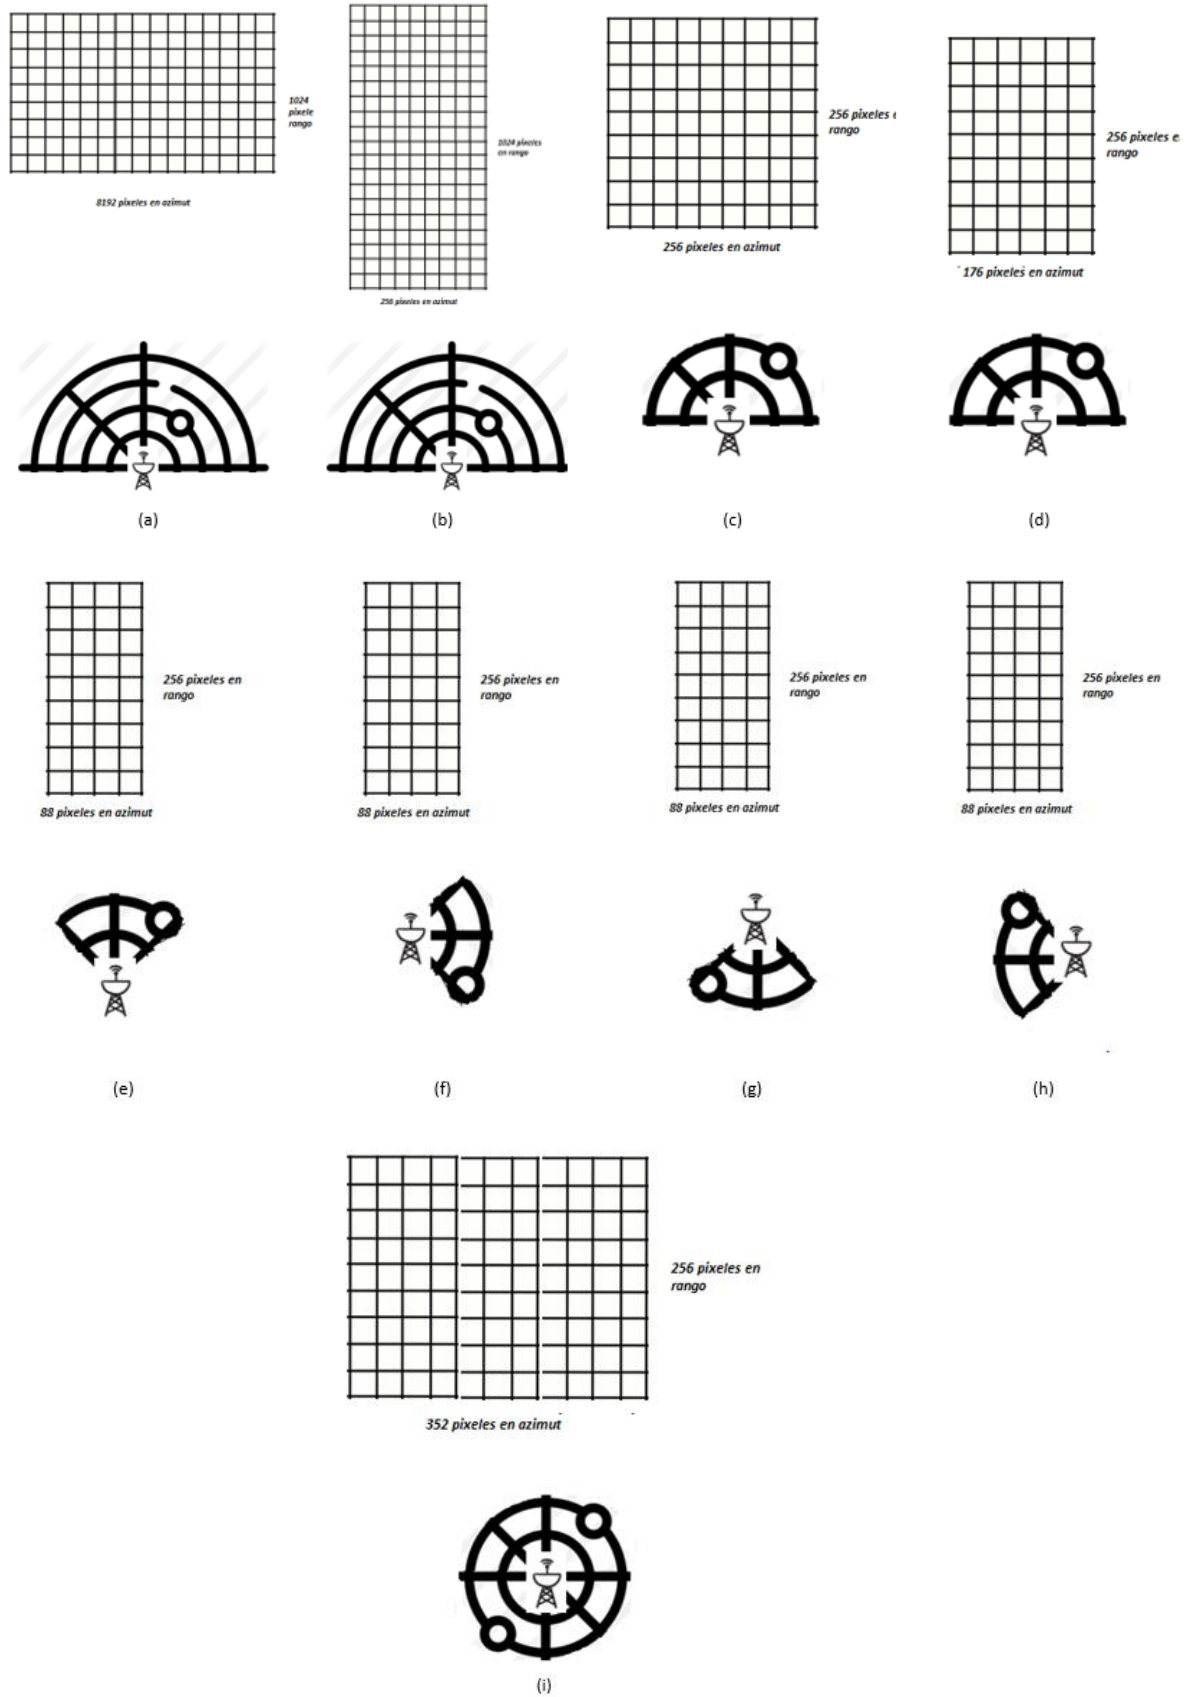


Figura 3.11. Composición de una vuelta de radar.

3.5.2. Clasificación de calidad de señal

En el estado del arte las técnicas de detección de movimiento [22] [23] son generalmente realizadas con la técnica de la interferometría en adquisiciones de señales de radar del tipo discreta. La técnica de interferometría utiliza tan solo un par de puntos en el tiempo de la misma región analizada para realizar el cálculo del movimiento y el criterio de selección de calidad de señal adquirida utilizada es la coherencia. Si la señal sobrepasa el límite de coherencia mínima aceptada, se considera que la calidad es buena.

Desafortunadamente en las adquisiciones de señales de radar del tipo continua no es aplicable, de forma directa, el concepto de coherencia como clasificador de calidad de señal que sea apta para la detección de movimientos. Es por ello que se realizó un estudio de las características que describen la calidad de una señal de radar con las especificaciones utilizadas en esta tesis.

3.5.3. Calidad de la señal, movimientos sintéticos y descriptores

Para el proceso de clasificación de señal se necesitaba conocer el fenómeno electromagnético que rige la naturaleza de los datos adquiridos y las principales distorsiones que sufre la señal. Es así como se generaron 120000 tramas sintéticas de fase en donde se simulan 120000 movimientos (un movimiento por cada trama) donde se conoce a priori la cantidad de ruido y el tipo de distorsión que tiene cada una de las tramas.

Las tramas de fase tendrán la siguiente forma:

$$trama_G(t) = A_G(t)e^{j\varphi_G(t)}, \text{ para } t = 1, 2, \dots, T \text{ y } G = 1, 2, \dots, 120000 \quad (37)$$

En la literatura, los estimadores empleados para la detección de movimiento refuerzan la información usando estadísticas no solo temporales sino también espaciales por lo que se agruparon las tramas de fase en una matriz tridimensional de 100 pixeles en azimut, 100 pixeles en rango y T instantes de tiempo de adquisición. A esta matriz tridimensional también se le conoce como *stack* [24]-[25]. Se forman con las 120000 tramas de señal 12 *stacks*. En la Figura 3.12 se muestra la composición de un *stack*.




Figura 3.12. Formación de un *stack*.

Cada *stack* tiene movimientos tales que no superan una longitud de onda en dirección hacia el radar o alejándose de él para no generar ambigüedades. Las características de cada *Stack* se muestran en la Tabla 3.3

Tabla 3.3. Característica de cada *Stack*.

10000 movimientos para cada <i>stack</i> de 100x100		15 SNR	20 SNR	25 SNR
Movimientos correlacionados en el espacio	Área plana	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$
	Área rugosa	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$
Movimientos no correlacionados en el espacio	Área plana	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$
	Área rugosa	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$	$[-\lambda, \lambda]$

Se planea utilizar los movimientos sintéticos en rango de $[-\lambda, \lambda]$ para evaluar el desempeño de los estimadores que serán utilizados posteriormente.


Como se muestra en la Tabla 3.3, una de las características de los *stacks* es la correlación espacial entre los movimientos de la matriz, esta característica, en un escenario real, solo puede ser evaluada después de la detección de movimientos. Por ello, se proponen 9 descriptores de calidad para diferenciar la calidad de señal de radar. A estos descriptores se le pueden clasificar en dos categorías: anterior a la detección de movimiento y posterior a la detección de movimiento.

A continuación se mencionan los descriptores en la Tabla 3.4.


Tabla 3.4. Descriptores utilizados para la clasificación de la calidad de la señal de radar

	Descriptor
Anterior a la detección de movimiento	Promedio de derivadas temporales
	Desviación estándar de la trama en el tiempo
	Rango dinámico de la trama en el tiempo
	Correlación espacial en azimut de las tramas en el tiempo
	Correlación espacial en rango de las tramas en el tiempo
Posterior a la detección de movimiento	Movimiento sintético detectado
	Gradiente a la derecha de la matriz de movimientos detectados
	Gradiente a la izquierda de la matriz de movimientos detectados
	Movimientos suavizados con kernel [1x3] (3 pixeles en el sentido del azimut)

Se muestra en la Figura 3.13 dos tramas aleatoriamente seleccionada. Y en Figura 3.14 dos matrices de movimientos sintéticos correspondientes a dos *stacks*.




(a)




(b)

Figura 3.13. Tramas sintéticas (a) Trama con baja SNR y movimiento alejándose al radar (b) Trama con buena SNR y saltos de fase con movimiento en dirección al radar.



(a)



(b)

Figura 3.14. Movimientos sintéticos en forma matricial para cada *Stack*. (a) Movimientos con baja correlación espacialmente (b) Movimientos con alta correlación espacial.

Los primeros 5 descriptores utilizan información directamente sobre el *stack* de información por lo que son calculados antes de la detección de movimiento, sin embargo, los últimos 4 descriptores procesan la información del movimiento detectado, por lo que son calculados sobre la matriz de movimiento, es decir, después de la aplicación del estimador.

A continuación, se detalla cada uno de los descriptores utilizados.

3.5.3.1. Promedio de derivadas temporales

Este descriptor tiene como objetivo determinar el nivel de ruido y saltos de fase existen en cada trama $trama_M$. Esta información es relevante debido a que el ruido puede producir saltos de fase no deseados. Se calcula de la siguiente manera:

$$des_1^G = \frac{1}{T} \sum_{t=1}^T \frac{d \arg(trama_G(t))}{dt} \quad (38)$$

Mientras más alto sea el valor de des_1^G , más presencia de ruido y saltos de fase habrá en la trama $trama_G(t)$. Si des_1^G es bajo, se trata de una trama con bajo nivel de ruido y sin distorsiones. Se muestra en la Figura 3.15 que información del *stack* está siendo utilizada.




Figura 3.15. Información del *stack* utilizada para cálculo del primer descriptor.

3.5.3.2. Desviación estándar de la trama en el tiempo

La desviación estándar de la trama nos da una noción de la dispersión de los valores de fase que representan un movimiento. Para hallar la desviación estándar, el primer paso es hallar el promedio de fases.

$$\mu_{trama}^G = \frac{1}{T} \sum_{t=1}^T \arg(trama_G(t)) \quad (39)$$

Luego, se procede a hallar la desviación estándar:

$$des_2^G = \frac{1}{T} \sum_{t=1}^T \sqrt{(\arg(trama_G(t)) - \mu_{trama}^G)^2} \quad (40)$$

Por la naturaleza de los movimientos de suelo, un valor de desviación estándar bajo corresponde a una trama libre de distorsión, sin embargo, una desviación estándar alta corresponde a una trama como nivel alto de ruido y con distorsiones. Se muestra en la Figura 3.16 que información del stack está siendo utilizada.




Figura 3.16. Información del stack utilizada por el segundo descriptor.

3.5.3.3. Rango dinámico de la trama en el tiempo

Este descriptor está enfocado principalmente a la búsqueda de saltos de fase. Se calcula de la siguiente forma:

$$\delta_{min}^G = \min(\arg(trama_G(t))) \quad (41)$$

$$\delta_{max}^G = \max(\arg(trama_G(t))) \quad (42)$$

Por último:

$$des_3^G = |\delta_{max}^G - \delta_{min}^G| \quad (43)$$

La fase está doblada en el rango de $-\pi$ a π . Si el valor de des_3^G es de 2π , se presumen dos hipótesis: 1) el movimiento en ese intervalo de señal es mayor o igual a una longitud de onda o 2) existen saltos de fase debido al dobles de fase. Se muestra en la Figura 3.17 que información del stack está siendo utilizada.




Figura 3.17. Información del stack utilizada por el tercer descriptor.

3.5.3.4. Correlación espacial en azimut de las tramas en el tiempo

Los *Stacks* de información de radar que se obtienen a este punto del pre-procesamiento contienen solo los movimientos lentos que se producen en una región, por ello, las tramas de fase de los pixeles espaciales contiguos en azimut del *Stack* suelen tener correlación. La forma de medir esta correlación se propone a continuación.

Definimos $Stack(r, \theta, t)$ como una matriz tridimensional con información en el rango, azimut y tiempo respectivamente.

Para facilitar la notación, se definen tres tramas de fase de la matriz del *Stack*

$$A_{-1} = \arg(Stack(r, \theta - 1, t)) \quad (44)$$

$$A_0 = \arg(Stack(r, \theta, t)) \quad (45)$$

$$A_1 = \arg(Stack(r, \theta + 1, t)) \quad (46)$$

Se calcula la correlación para cada pixel contra sus dos vecinos en azimut.

$$CA_{-1}(r, \theta) = \frac{\sum_{t=1}^T (A_0 - \bar{A}_0)(A_{-1} - \bar{A}_{-1})}{\sqrt{\sum_{t=1}^T (A_0 - \bar{A}_0)^2} \sqrt{\sum_{t=1}^T (A_{-1} - \bar{A}_{-1})^2}} \quad (47)$$

$$CA_1(r, \theta) = \frac{\sum_{t=1}^T (A_0 - \overline{A_0})(A_1 - \overline{A_1})}{\sqrt{\sum_{t=1}^T (A_0 - \overline{A_0})^2} \sqrt{\sum_{t=1}^T (A_1 - \overline{A_1})^2}} \quad (48)$$

El descriptor propuesto será el promedio de estos dos coeficientes de correlación.

$$des_4^G = \frac{CA_1(r, \theta) + CA_{-1}(r, \theta)}{2} \quad (49)$$

La correlación está definida entre el rango de -1 a 1, por lo que el descriptor des_4^G también se encuentra en ese rango. Mientras más cercano esté a uno este descriptor, mejor desempeño tendrán los estimadores de movimientos que utilizan las características espaciales para reforzar el movimiento detectado. Se muestra en la Figura 3.18 que información del stack está siendo utilizada.




Figura 3.18. Información del stack utilizada por el cuarto descriptor.

3.5.3.5. Correlación espacial en rango de las tramas en el tiempo

De forma muy similar al descriptor anterior, se utiliza un descriptor que muestre la característica espacial de las tramas de fase dentro de la matriz *Stack*, esta vez comparando cada pixel en con sus vecinos en el sentido del rango.

Se define:

$$R_{-1} = \arg(Stack(r - 1, \theta, t)) \quad (50)$$

$$R_0 = \arg(Stack(r, \theta, t)) \quad (51)$$

$$R_1 = \arg(\text{Stack}(r + 1, \theta, t)) \quad (52)$$

Los coeficientes de correlación en el sentido del rango para ambos vecinos serán:

$$CR_{-1}(r, \theta) = \frac{\sum_{t=1}^T (R_0 - \bar{R}_0)(R_{-1} - \bar{R}_{-1})}{\sqrt{\sum_{t=1}^T (R_0 - \bar{R}_0)^2} \sqrt{\sum_{t=1}^T (R_{-1} - \bar{R}_{-1})^2}} \quad (53)$$

$$CR_1(r, \theta) = \frac{\sum_{t=1}^T (R_0 - \bar{R}_0)(R_1 - \bar{R}_1)}{\sqrt{\sum_{t=1}^T (R_0 - \bar{R}_0)^2} \sqrt{\sum_{t=1}^T (R_1 - \bar{R}_1)^2}} \quad (54)$$

El descriptor utilizado también será el promedio de los dos coeficientes de correlación de cada pixel contra sus vecinos, pero esta vez en el sentido del rango.

$$des_5^G = \frac{CR_1(r, \theta) + CR_{-1}(r, \theta)}{2} \quad (55)$$

Este descriptor también se encuentra en el rango de -1 a 1. Siendo 1 la mejor calidad de correlación espacial en el sentido del rango que favorece la detección de movimientos. Se muestra en la Figura 3.19 que información del stack está siendo utilizada.




Figura 3.19. Información del stack utilizada por el quinto descriptor.

3.5.3.6. Movimiento detectado

Como se mencionó previamente, una de las características que influye en la calidad de la detección de movimientos es la correlación y similitud espacial de los movimientos

en la zona en análisis. Los problemas de saltos de fase suelen corromper la información de movimientos muy pequeños, es decir, los movimientos pequeños tienen mayor probabilidad de ser detectados incorrectamente. Por ello, des_6^G es por sí mismo el movimiento hallado y un descriptor a la vez. Se muestra en la Figura 3.20 que información de la matriz de movimientos está siendo utilizada




Figura 3.20. Información de la matriz de movimientos utilizada por el sexto descriptor.

3.5.3.7. Diferenciales de la matriz de movimientos detectados

Una forma de medir la homogeneidad de la superficie que se está evaluando es analizar cómo se comportan los movimientos haciendo un análisis de sus características espaciales. Como la cantidad de área, que representa un pixel en el sentido del rango es variable, se decide solo analizar las similitudes en el sentido del azimut.

La matriz tridimensional de señal de radar $Stack(r, \theta, t)$ genera una matriz de movimientos hallados $Mov(r, \theta)$. Los descriptores: diferencial a la derecha y diferencial a la izquierda se definen a continuación

$$des_7^G = |Mov(r, \theta) - Mov(r, \theta + 1)| \quad (56)$$

$$des_8^G = |Mov(r, \theta) - Mov(r, \theta - 1)| \quad (57)$$

Se muestra en la Figura 3.21 que información de la matriz de movimientos está siendo utilizada.




Figura 3.21. Información de la matriz de movimientos utilizada para el cálculo del sétimo y octavo descriptor. (a) Coloreado en rojo el pixel de interés para el sétimo descriptor (b) Coloreado en rojo el pixel de interés para el octavo descripto.

3.5.3.8. Movimientos suavizados

Este descriptor se define como el promedio de movimiento de cada trama y sus vecinos próximos en el sentido del azimut.

Nuevamente, $Stack(r, \theta, t)$ genera una matriz de movimientos detectados $Mov(r, \theta)$. El descriptor queda definido de la siguiente forma:

$$des_9^G = \frac{Mov(r, \theta) + Mov(r, \theta - 1) + Mov(r, \theta + 1)}{3} \quad (58)$$

Este descriptor da una noción del movimiento esperado si la correlación espacial es bastante alta. En caso la correlación espacial sea baja, habrá una diferencia notable entre des_6^G y des_9^G . Se muestra en la Figura 3.22 que información de la matriz de movimientos está siendo utilizada.




Figura 3.22. Información de la matriz de movimientos utilizada para el cálculo del noveno descriptor.

3.5.4. Diagrama del método para el cálculo de movimiento efectivo

Una vez definidos los descriptores de calidad de señal de radar que serán utilizados para clasificar los movimientos efectivos de los movimientos erróneos debido a las distorsiones y ruido, se plantea la secuencia del método propuesto en la Figura 3.23.

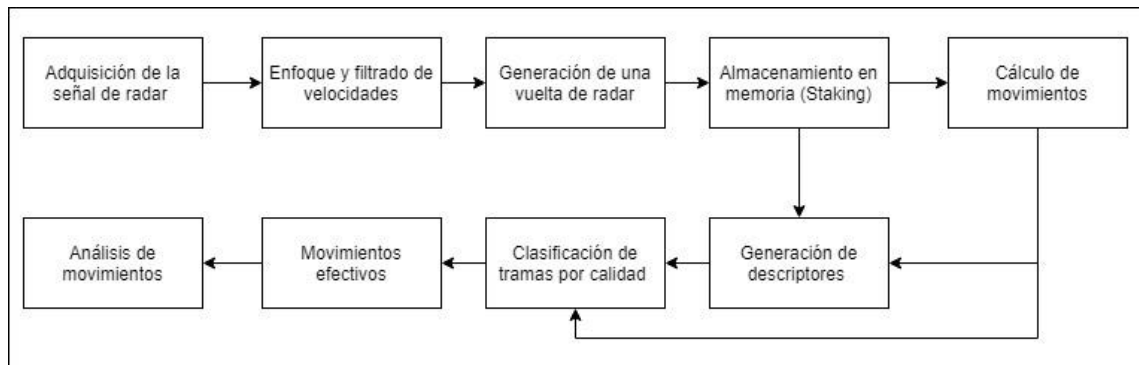


Figura 3.23. Diagrama de bloques del método propuesto.

3.5.5. Cálculo de movimiento acumulado

Para el cálculo de fase de movimiento hacemos el uso de 3 estimadores, cada uno con particularidades en sus algoritmos que aprovechan las características espaciales y temporales de la naturaleza de la señal en estudio. Los 3 estimadores son: media simple (MS), Media espacio-temporal (XY-T) y el estimador por mínimos cuadrados ponderados (WLS por sus siglas en inglés).

Para la elección del mejor estimador de movimiento se utiliza el proceso descrito en la Figura 3.24.

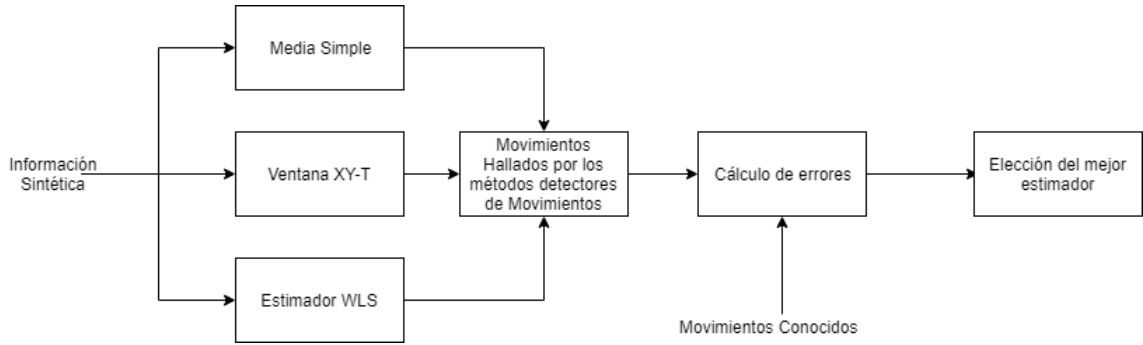


Figura 3.24. Método para la elección del mejor estimador de movimiento.

Se emplean los datos de radar sintéticos agrupados en *stacks* para determinar que algoritmo es el que mejor desempeño tiene y hallar el movimiento a pesar de las distorsiones debido al ruido y saltos de fase.

Los estimadores serán desarrollados a continuación y se explicarán los beneficios con los que cuentan cada uno de ellos.

3.5.5.1. Media simple en el tiempo

Este estimador de movimiento utiliza el concepto de eliminación de ruido gaussiano, que es la distribución de ruido de fase que se tiene en la matriz de datos, haciendo un promedio simple de las muestras durante el tiempo de integración.

Se define la siguiente trama de señal:

$$trama_{\theta}^r(t) = A_{\theta}^r(t)e^{j\varphi_{\theta}^r(t)}, t = 1, 2, \dots, T \quad (59)$$

Siendo $trama(t)_{\theta}^r$ la señal adquirida por el radar para cada coordenada espacial (r, θ). Ahora, se divide dicha trama en dos periodos de tiempo, la primera mitad y la segunda a las cuales se les llamará como trama $B_1(t)$ y $B_2(t)$.

$$B_{1\theta}^r(t) = trama_{\theta}^r(t), t = 1, 2, \dots, T/2 \quad (60)$$

$$B_{2\theta}^r(t) = trama_{\theta}^r(t), t = \frac{T}{2} + 1, \frac{T}{2} + 2, \dots, T \quad (61)$$

El cálculo del movimiento se realizará restando el promedio de fases de las tramas de $B_1(t)$ y $B_2(t)$, este proceso se muestra en la Ecuación (62)

$$MOV_{MS}(r, \theta) = \arg(E[B_1(t)]conj(E[B_2(t)])) \frac{\lambda}{4\pi} \quad (62)$$

3.5.5.2. Ventana espacio temporal

De la misma manera que el método anterior, la ventana espacio temporal utiliza el criterio de eliminación de ruido usando el teorema del límite central [20]. La diferencia es que esta vez no se utilizan tramas aisladas en el espacio, sino que el promedio de

datos para el cálculo de la fase se realiza reforzando la información de cada pixel con la información de los pixeles vecinos. De la Ecuación (60) y Ecuación (61) definimos ahora las ventanas espaciales para cada pixel:

$$V_{1\theta}^r(t) = [B_{1\theta-1}^r(t) \quad B_{1\theta}^r(t) \quad B_{1\theta+1}^r(t)] \quad (63)$$

$$V_{2\theta}^r(t) = [B_{2\theta-1}^r(t) \quad B_{2\theta}^r(t) \quad B_{2\theta+1}^r(t)] \quad (64)$$

El movimiento que se encuentra en la información de la señal $trama_{\theta}^r(t)$ queda definido por:

$$MOV_{XY-T}(r, \theta) = \arg(E[V_1(t)]conj(E[V_2(t)])) \frac{\lambda}{4\pi} \quad (65)$$

Este estimador de movimiento presupone que la correlación espacial de la zona alumbrada por el radar es alta. De ser así, la reducción de ruido *speckle* es bastante buena, sin embargo, si la correlación espacial es baja la información del movimiento puede verse afectada de forma considerable.

3.5.5.3. Estimación por mínimos cuadrados ponderados

Este estimador de fase, pondera las fases de las matrices detectadas en el periodo de integración T según la similitud o dispersión que ellas tengan. Luego de calificar a cada muestra de fase a través del tiempo según su correlación con el resto de la trama, se realiza una regresión lineal y así se detecta el valor de fase correspondiente al movimiento del pixel en estudio en el tiempo T .

Partimos del modelo utilizado por [26] para el cálculo de movimientos de una señal de duración T de la forma $trama(t)_{\theta}^r = A(t)_{\theta}^r e^{j\varphi(t)_{\theta}^r}$, donde se propone el siguiente método para resolver el movimiento de fase correspondiente al desplazamiento de un objeto. Partimos por el cálculo de β :

$$\beta = (A^T W A)^{-1} A^T W D \quad (66)$$

Donde D es el vector de fases interferométricas de $trama_{\theta}^r(t)$ en el tiempo de integración T :

$$D = \begin{bmatrix} \psi_{1,2}^{int} \\ \psi_{2,3}^{int} \\ \psi_{3,4}^{int} \\ \vdots \\ \psi_{T-1,T}^{int} \end{bmatrix}$$

La matriz A tiene la siguiente forma:

$$A = \begin{bmatrix} 1 & 0 & \cdot & \cdot & 0 & 0 \\ 1 & -1 & 0 & 0 & 0 & \cdot \\ 1 & 0 & -1 & 0 & 0 & \cdot \\ \cdot & 0 & 0 & 0 & 0 & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot & 0 \\ 0 & 0 & \cdot & \cdot & 1 & -1 \end{bmatrix}$$

Con tamaño de $[M T]$ donde M es el resultado de $\frac{T!}{(T-2)!2!}$ y \mathbf{W} es la matriz de pesos que correspondiente a la ecuación propuesta en [8].

$$W = \begin{bmatrix} c_{1,2} & c_{1,2} & \cdot & \cdot & c_{1,2} & c_{1,2} \\ c_{2,3} & c_{2,3} & \cdot & \cdot & c_{2,3} & c_{2,3} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ c_{T-1,T} & c_{T-1,T} & \cdot & \cdot & c_{T-1,T} & c_{T-1,T} \end{bmatrix}$$

con dimensión de $[M M]$. Por otro lado, se calcula el vector de ponderaciones cov para el cálculo de la regresión lineal:

$$cov = \sqrt{diag(\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1}} \quad (67)$$

Entonces, la regresión lineal ponderada será de la siguiente manera:

$$\mathbf{C} = (\mathbf{P}^T \mathbf{\Omega} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{\Omega} \mathbf{P} \quad (68)$$

Siendo $\mathbf{\Omega}$ una matriz cuadrada con diagonal igual a cov . La matriz \mathbf{X} tendrá la siguiente forma:

$$\mathbf{P} = \begin{bmatrix} 1 & 1 \\ 2 & 1 \\ 3 & 1 \\ \vdots & \vdots \\ \cdot & \cdot \\ T & 1 \end{bmatrix}$$

La dimensión de \mathbf{C} será de $[2 1]$ y tendrá la forma $\begin{bmatrix} m \\ b \end{bmatrix}$ que son los parámetros de la recta (pendiente y punto de corte con el eje de las ordenadas respectivamente) que define el movimiento del objeto en el tiempo T .

Finalmente, el movimiento estimado por el método de mínimos cuadrados ponderados se determina de la siguiente forma:

$$mov_{WLS} = Tm \frac{\lambda}{4\pi} \quad (69)$$

De la Ecuación (66) a la Ecuación (69) son aplicadas a todos los píxeles de la matriz *Stack* para todas las coordenadas (r, θ) , obteniendo la matriz de movimientos $MOV_{WLS}(r, \theta)$.

3.5.6. Clasificación de tramas de señal utilizando los descriptores y una red neuronal

Habiendo seleccionado el mejor estimador de movimiento, se requiere clasificar los movimientos originados por tramas con calidad buena y los movimientos originados por tramas con mala calidad. Al aplicar el estimador de movimiento a las tramas con mala calidad no se cumple con el objetivo de hallar el movimiento de forma correcta.

Por ello se propone utilizar una red neuronal de reconocimiento de patrones para cada trama, en donde la entrada a la red serán los 9 descriptores mencionados previamente y las salidas esperadas serán binarias: uno en caso el estimador de movimiento halló el movimiento de forma correcta y cero si el estimador de movimiento no consiguió calcular el movimiento de forma correcta.

Para entrenar a la red neuronal se requiere de información etiquetada, por ello, se utilizó la información sintética $trama_G(t)$ y se calculó para cada una de las M tramas los 9 descriptores de calidad.

Una vez definidas las entradas y la salida de la red de clasificación se utilizó la aplicación *nprtool* de MATLAB. La arquitectura utilizada tiene los parámetros mostrados en la Tabla 3.5.

Tabla 3.5. Parámetro de la red neuronal de reconocimiento de patrones.

Parámetro	Configuración
Número de entradas	9
Tipo de entradas	Discretas
Capas	2
Número de neuronas en la capa oculta	19
Salida	Binaria
Función de activación de la capa oculta	Sigmoide hiperbólica tangente
Función de activación de la capa de salida	Logsig binaria
Número de derivadas	6
Algoritmo de entrenamiento	Back propagation

Las 120000 tramas fueron separadas de la siguiente forma: 70% entrenamiento, 15% validación y 15% de prueba. Cabe resaltar que la cantidad de neuronas en la capa oculta fue variada para ver el desempeño de la red neuronal artificial. Con 19 neuronas se cumple con el criterio propuesto por [27] y experimentalmente, aumentar el número de neuronas no mejora la precisión de la red propuesta. Los resultados del entrenamiento serán mostrados en el Capítulo IV.

Luego del entrenamiento de la red neuronal artificial, esta será utilizada como clasificador de calidad de la señal. Denotando a esta red como un estimador de función:

$$f_{rp}(des_1^M, des_2^M, \dots, des_9^M) = \begin{cases} 1 & \text{descriptores con buena calidad} \\ 0 & \text{descriptores con mala calidad} \end{cases} \quad (70)$$

Donde se descartan los movimientos provocados por tramas de señal ruidosas y con altos niveles de distorsión. El diagrama de este método se muestra en la Figura 3.25.

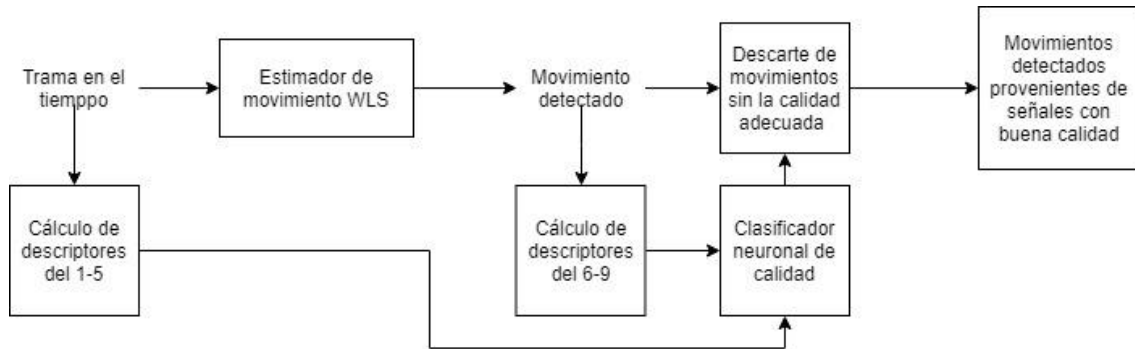


Figura 3.25. Método de cálculo de descriptores, cálculo de movimientos y clasificación de calidad de señal.

3.5.7. Cálculo de velocidad y aceleración de los movimientos geodinámicos

Para todos los estimadores propuestos se ha detectado el movimiento *mov*. La velocidad con la que se efectúan los movimientos, está definida por la variación de movimiento sobre el tiempo en el cual este movimiento se realizó:

$$vel(t) = \frac{\partial mov(t)}{\partial t} \quad (71)$$

De igual manera, la aceleración queda definida por la variación de velocidad en el tiempo de integración *T*:

$$acel(t) = \frac{\partial vel(t)}{\partial t} \quad (72)$$

CAPITULO IV

PRUEBAS Y RESULTADOS

En este capítulo se mostrarán los resultados obtenidos para la metodología propuesta en el Capítulo III. La elección del mejor estimador de movimientos cuyo desempeño es eficiente para la naturaleza de las señales de radar adquiridas en este experimento, tienen un aporte en la adaptación de las técnicas del estado del arte, puesto que en la mayoría de aplicaciones de monitoreo de suelos utilizando señales de radar se utiliza la técnica de adquisición de tipo discreta. La etapa de selección del mejor tiempo de integración, elección de descriptores y arquitectura de la red neuronal artificial para la etapa de clasificación son los aportes de este trabajo de tesis.

4.1. Selección del mejor estimador de movimientos

Como no se dispone de un experimento real en donde se tengan movimientos controlados para poder probar el desempeño del detector de movimiento, se generaron 120000 tramas de fase agrupadas en 12 *stacks* de 100 pixeles en azimut y 100 pixeles en rango. La finalidad de agrupar las tramas sintéticas en *stacks*, es darle la forma de la información adquirida que presenta el experimento real de monitoreo de suelos utilizando un radar de banda X con tipo de adquisición continua. La información sintética comprende movimientos pequeños y grandes con respecto a la longitud de onda utilizada (que es la referencia para no incurrir en ambigüedades), diferentes condiciones geográficas, distorsiones por saltos de fase y diferentes niveles de ruido.

A cada *Stack* se le aplicaron los 3 estimadores de movimiento: MS, XY-T y WLS. Luego que los movimientos fueron hallados se midió el desempeño comparándolo con el movimiento ideal que se conoce *a priori* puesto que se trata de información sintética (es decir, se dispone del movimiento ideal que cada trama sintética de señal contiene, y se tiene el movimiento calculado luego de aplicarle los estimadores a cada trama). Como se mostró en el Capítulo III, se tiene una tolerancia máxima con el cual el movimiento se sigue considerando detectado correctamente. Esta tolerancia (en porcentaje) significa la diferencia máxima aceptada entre el movimiento ideal y el movimiento calculado por el estimador, sea esta diferencia positiva o negativa. En la Figura 4.1 se muestra la secuencia de pasos para la comparación del desempeño de los estimadores.

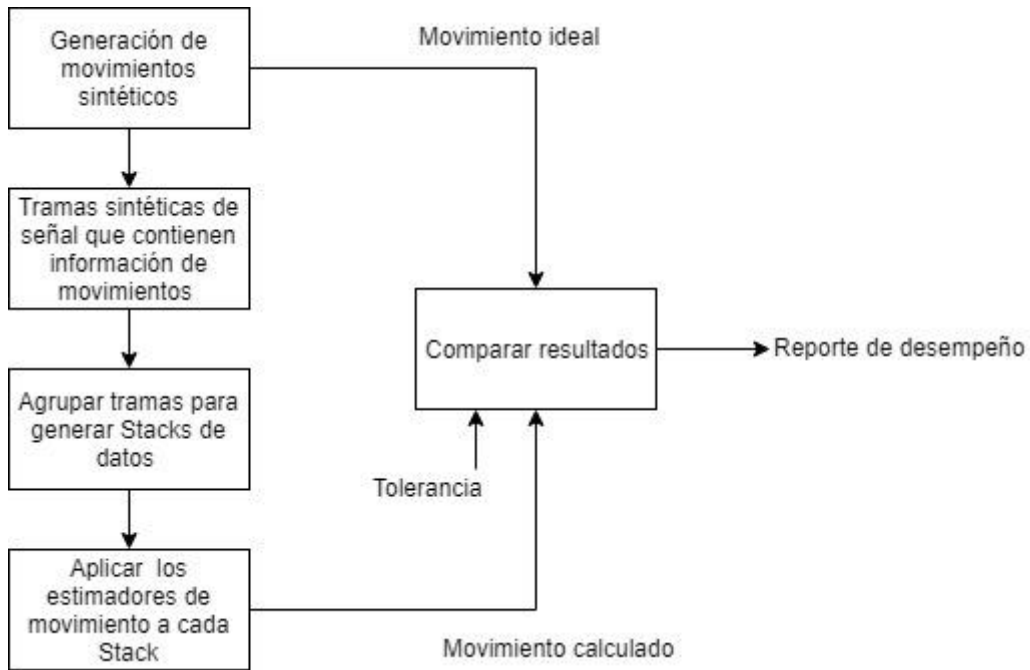


Figura 4.1. Secuencia de pasos para la comparación del desempeño de estimadores.

Luego de implementar los estimadores de movimiento, estos son aplicados a las tramas sintéticas de señal que se agruparon en forma de *Stack*. Las tramas sintéticas fueron generadas de tal forma que el movimiento que debe ser hallado por los estimadores son conocidos y que serán denotados como MOV_{sint}^M , con $M = 1, 2, \dots, 120000$ para cada una de las tramas generadas. El superíndice M reemplaza a las coordenadas (r, θ) debido a que con esta información sintética no es relevante la localización exacta en las cuales los estimadores tuvieron un buen desempeño, sino solo la cantidad de ellas.

La estrategia de selección del mejor estimador de movimiento es aquel que tenga la menor cantidad de movimientos detectados erróneamente a pesar de una cierta tolerancia. Se muestra a continuación dicho procedimiento:

$$E_{MS}^G = \begin{cases} 1 & , (1 - tol)MOV_{sint}^G < MOV_{MS}^G < (1 + tol)MOV_{sint}^G \\ 0 & \text{en otro caso} \end{cases} \quad (73)$$

$$E_{XY-T}^G = \begin{cases} 1 & , (1 - tol)MOV_{sint}^G < MOV_{XY-T}^G < (1 + tol)MOV_{sint}^G \\ 0 & \text{en otro caso} \end{cases} \quad (74)$$

$$E_{WLS}^G = \begin{cases} 1 & , (1 - tol)MOV_{sint}^G < MOV_{WLS}^G < (1 + tol)MOV_{sint}^G \\ 0 & \text{en otro caso} \end{cases} \quad (75)$$

Donde tol es la tolerancia de error permitida para cada movimiento detectado.

Luego, se halla la cantidad de tramas donde el estimador no tuvo buen desempeño.

$$\%error_{MS} = 100 \times \left[\frac{1}{120000} \sum_{G=1}^{120000} E_{MS}^G \right] \quad (76)$$

$$\%error_{XY-T} = 100 \times \left[\frac{1}{120000} \sum_{G=1}^{120000} E_{XY-T}^G \right] \quad (77)$$

$$\%error_{WLS} = 100 \times \left[\frac{1}{120000} \sum_{G=1}^{120000} E_{WLS}^G \right] \quad (78)$$

La elección del estimador a utilizar para la detección de movimientos será el que origina el menor error porcentual entre: $\%error_{MS}$, $\%error_{XY-T}$ y $\%error_{WLS}$.

Los resultados para el estimador MS con tolerancias de 5%, 10% y 15% se muestran en la Tabla 4.1, Tabla 4.2 y Tabla 4.3. Para estos diferentes valores de tolerancia se puede observar que la tendencia de errores porcentuales se mantenía es siempre la misma para los tres estimadores.

Tabla 4.1. Errores porcentuales de cálculo de movimiento para el estimador MS y 5% de tolerancia de error.

Tolerancia 5%		15 SNR ($\%error_{MS}$)	20 SNR ($\%error_{MS}$)	25 SNR ($\%error_{MS}$)
Errores para movimientos correlacionados en el espacio (%)	Área plana	99.97	99.98	99.98
	Área rugosa	99.47	99.65	99.73
Errores para movimientos no correlacionados en el espacio (%)	Área plana	97.69	96.83	97.68
	Área rugosa	97.50	97.42	97.76

Tabla 4.2. Errores porcentuales de cálculo de movimiento para el estimador MS y 10% de tolerancia de error.

Tolerancia 10%		15 SNR ($\%error_{MS}$)	20 SNR ($\%error_{MS}$)	25 SNR ($\%error_{MS}$)
Errores para movimientos correlacionados en el espacio (%)	Área plana	99.96	99.96	99.96
	Área rugosa	99.27	99.54	99.63
Errores para movimientos no correlacionados en el espacio (%)	Área plana	96.91	97.62	96.84
	Área rugosa	96.63	96.44	96.92

Tabla 4.3. Errores porcentuales de cálculo de movimiento para el estimador MS y 15% de tolerancia de error.

Tolerancia 15%		15 SNR (%error _{MS})	20 SNR (%error _{MS})	25 SNR (%error _{MS})
Errores para movimientos correlacionados en el espacio (%)	Área plana	99.93	99.94	99.95
	Área rugosa	98.86	99.33	99.53
Errores para movimientos no correlacionados en el espacio (%)	Área plana	95.99	95.89	95.89
	Área rugosa	95.51	95.49	95.98

Los resultados para el estimador XY-T con tolerancias de 5%, 10% y 15% se muestran en la Tabla 4.4, Tabla 4.5 y Tabla 4.6.

Tabla 4.4. Errores porcentuales de cálculo de movimiento para el estimador XY-T y 5% de tolerancia de error.

Tolerancia 5%		15 SNR (%error _{XY-T})	20 SNR (%error _{XY-T})	25 SNR (%error _{XY-T})
Errores para movimientos correlacionados en el espacio (%)	Área plana	99.99	99.98	99.98
	Área rugosa	95.53	99.38	99.56
Errores para movimientos no correlacionados en el espacio (%)	Área plana	95.05	94.95	95.12
	Área rugosa	96.03	95.35	95.46

Tabla 4.5. Errores porcentuales de cálculo de movimiento para el estimador XY-T y 10% de tolerancia de error.

Tolerancia 10%		15 SNR (%error _{XY-T})	20 SNR (%error _{XY-T})	25 SNR (%error _{XY-T})
Errores para movimientos correlacionados en el espacio (%)	Área plana	99.98	99.98	99.98
	Área rugosa	94.04	99.04	99.35
Errores para movimientos no correlacionados en el espacio (%)	Área plana	93.02	93.15	93.16
	Área rugosa	94.60	93.59	93.82

Tabla 4.6. Errores porcentuales de cálculo de movimiento para el estimador XY-T y 15% de tolerancia de error.

Tolerancia 15%		15 SNR (%error _{XY-T})	20 SNR (%error _{XY-T})	25 SNR (%error _{XY-T})
Errores para movimientos correlacionados en el espacio (%)	Área plana	99.98	99.98	99.98
	Área rugosa	92.33	98.71	99.10
Errores para movimientos no correlacionados en el espacio (%)	Área plana	91.06	91.42	91.60
	Área rugosa	93.04	91.90	92.16

Los resultados para el estimador WLS con tolerancias de 5%, 10% y 15% se muestran en la Tabla 4.7, Tabla 4.8 y Tabla 4.9.

Tabla 4.7. Errores porcentuales de cálculo de movimiento para el estimador WLS y 5% de tolerancia de error.

Tolerancia 5%		15 SNR (%error _{WLS})	20 SNR (%error _{WLS})	25 SNR (%error _{WLS})
Errores para movimientos correlacionados en el espacio (%)	Área plana	21.27	1.56	0.09
	Área rugosa	17.85	10.02	5.79
Errores para movimientos no correlacionados en el espacio (%)	Área plana	89.26	88.37	88.42
	Área rugosa	88.94	88.35	88.23

Tabla 4.8. Errores porcentuales de cálculo de movimiento para el estimador WLS y 10% de tolerancia de error.

Tolerancia 10%		15 SNR (%error _{WLS})	20 SNR (%error _{WLS})	25 SNR (%error _{WLS})
Errores para movimientos correlacionados en el espacio (%)	Área plana	12.58	0.37	0.03
	Área rugosa	12.94	7.28	4.31
Errores para movimientos no correlacionados en el espacio (%)	Área plana	85.36	84.39	84.38
	Área rugosa	84.77	83.96	83.99

Tabla 4.9. Errores porcentuales de cálculo de movimiento para el estimador WLS y 15% de tolerancia de error.

Tolerancia 15%		15 SNR (%error _{WLS})	20 SNR (%error _{WLS})	25 SNR (%error _{WLS})
Errores para movimientos correlacionados en el espacio (%)	Área plana	7.67	0.11	0.02
	Área rugosa	9.95	5.48	3.35
Errores para movimientos no correlacionados en el espacio (%)	Área plana	81.23	79.96	79.93
	Área rugosa	80.79	79.96	79.48

Observando las tablas de desempeño de estimadores, se aprecia en las dos últimas filas desde la Tabla 4.1 hasta la Tabla 4.9 que los movimientos correlacionados espacialmente son hallados de forma correcta significativamente en mayor proporción que los movimientos no correlacionados espacialmente. Por otro lado, la heterogeneidad del terreno no es demasiado trascendente en el desempeño de los estimadores. Por último, como era de esperarse, mientras mayor es el nivel de ruido, menor es el acierto de los estimadores de movimiento.

En la Figura 4.2 se muestran los movimientos esperados de un *Stack* con buena correlación espacial en los movimientos, así como los movimientos hallados por cada estimador.

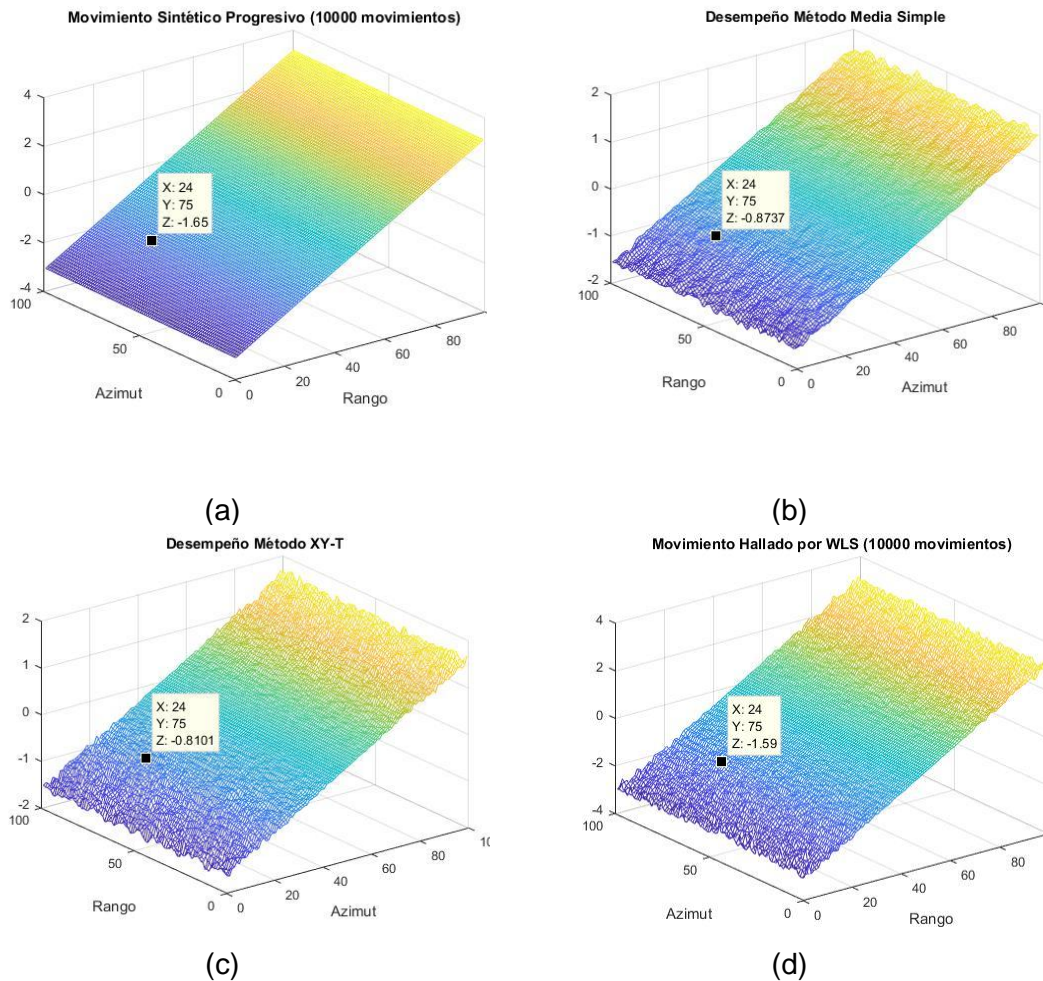


Figura 4.2. Desempeño de los estimadores. (a) Movimientos ideales sintéticos (b) Movimientos hallados por MS (c) Movimientos hallados por XY-T (d) Movimientos hallados por WLS.

Comparando los resultados con tolerancia de 5% de cada estimador, el que mejor desempeño presenta es el algoritmo WLS. Si bien es cierto que el desempeño falla en aproximadamente el 80% de datos con movimientos no correlacionados espacialmente (a comparación del casi 95% en promedio de los otros dos estimadores), en este experimento se buscó simular señales con una gran variedad de características espaciales y temporales, desde el experimento con condiciones más favorables hasta el experimento con condiciones muy adversas. La señal de radar de monitoreo de suelos se encuentra en un ambiente con condiciones de características espaciales altamente correlacionadas (movimientos similares entre los pixeles vecinos de la matriz de fases). Por lo tanto, el algoritmo WLS es el elegido como el estimador de movimiento con mejor desempeño.

En coordinaciones con el municipio de Xerém (que es la región en la que se implementó el método propuesto), las especificaciones técnicas que los especialistas en geodinámica solicitaron a BRADAR (empresa que facilitó el acceso a la base de datos de radar) como error máximo en la detección de movimiento fue de 5% y es por ello que ese será el valor de tolerancia en el diseño del método propuesto.

4.2. Elección del mejor tiempo de integración

Una vez elegido el estimador WLS se calcula el tiempo de integración utilizado para cada *Stack*. Para esta elección, se utilizó la información sintética $trama_G(t)$ agrupada en *Stack* de 100 pixeles en azimut y 100 pixeles en rango pero con duración en el tiempo desde 40 s hasta 7 min. Nuevamente, se utilizó la tolerancia de 5% y se hizo el cálculo de errores porcentuales donde los movimientos no fueron hallados de forma correcta. Los resultados se muestran en la Figura 4.3.




Figura 4.3. Errores porcentuales del estimador WLS para tramas de diferentes duraciones de tiempo.

Se observa en la Figura 4.3 una mejora importante para tiempos de integración desde 40 s hasta aproximadamente 3 min. Sin embargo, desde 3 min hasta 7 min solo se obtiene una mejora de 2% en el desempeño del estimador.

Por otro lado, el análisis del tiempo de procesamiento utilizado es importante también para conocer si esta aplicación puede ser utilizada en tiempo real. En la Figura 4.4, se muestra el tiempo de procesamiento que llevó el cálculo de movimientos mediante el estimador WLS en una computadora con procesador Intel i5 de séptima generación y con 8 gigabytes de memoria RAM.




Figura 4.4. Tiempo de procesamiento para el estimador WLS para tramas de diferentes duraciones de tiempo.

Aproximadamente hasta los 5 min de integración de la señal se tiene un tiempo de procesamiento menor o igual al tiempo procesamiento. Es decir que, para aplicaciones en tiempo real, se podría utilizar el estimador WLS con *stacks* de hasta 5 min de duración en el tiempo para hallar los movimientos en bruto.

En el método propuesto se utiliza también una etapa de clasificación de calidad de señal y se requiere hallar descriptores para cada uno de los *stacks*, por lo que se decide utilizar un tiempo de integración de 3.5 min para dar un intervalo de tiempo libre en el que la aplicación completa de los métodos propuestos funcione en tiempo real.

4.3. Análisis de descriptores de calidad

El método propuesto en este trabajo de tesis consta no solamente de la detección de los movimientos de un *Stack* de información sino también el descarte de los movimientos que corresponden a tramas de señal dentro del *Stack* que no cumplen con una calidad mínima para garantizar que el estimador WLS está funcionando de forma correcta.

Como se mencionó en los resultados del Subcapítulo 4.1, haciendo un análisis de la Tabla 4.7, los errores en el estimador incrementan cuando los *stacks* presentan movimientos poco correlacionados en el espacio. Además, existe una tendencia de incremento de error en la detección de movimientos mientras menor SNR tenga la señal adquirida. La heterogeneidad de la zona no influye demasiado en el incremento del error por lo que se esperan buenos resultados en zonas urbanas. Por último, se hizo un análisis de cuan probable es que una trama tenga buena o mala calidad dependiendo del movimiento que contenga en su información, para ello, se utilizaron todas las tramas

en donde el algoritmo WLS falló y se generó una función de densidad de probabilidad de errores (la cantidad de movimiento no será presentada en metros, sino será representada en función a la longitud de onda usada por el radar). Los resultados se muestran en la Figura 4.5.

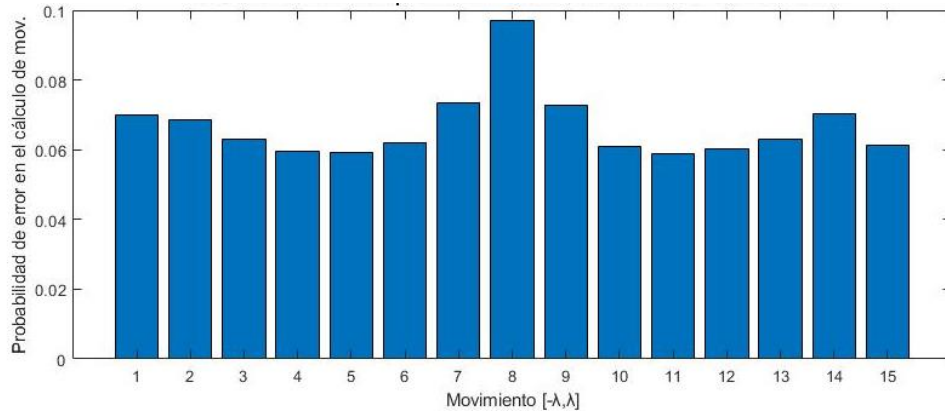


Figura 4.5. Función de densidad de probabilidad de errores según el movimiento.

Se observa que la mayor cantidad de errores se encuentran en los límites máximo y mínimos de movimiento y también en los movimientos muy cercanos al estado de reposo. Se presume que los errores en los movimientos bastante grandes se debe los saltos de fase y los errores en los movimientos pequeños se deben al ruido aditivo.

Se propusieron 9 descriptores de calidad, los cuales se pueden agrupar en 2 grandes grupos: antes de la detección del movimiento y después de la detección del movimiento.

A continuación, se menciona brevemente la característica que cada descriptor proporciona:

- Promedio de derivadas temporales (des_1^G): información sobre la cantidad de saltos de fase dentro de la trama.
- Desviación estándar de la trama en el tiempo (des_2^G): información acerca de que tan suave ha sido el movimiento en la trama.
- Rango dinámico de la trama en el tiempo (des_3^G): información sobre el doblamiento de la fase.
- Correlación espacial en azimut de las tramas en el tiempo (des_4^G): información sobre la correlación espacial de las tramas en azimut.
- Correlación espacial en rango de las tramas en el tiempo (des_5^G): información sobre la correlación espacial de las tramas en rango.
- Movimiento detectado (des_6^G): movimiento hallado.
- Diferenciales de la matriz de movimientos detectados (des_7^G y des_8^G): información sobre la diferencia de movimientos de cada pixel con sus vecinos en azimut.

- Movimientos suavizados (des_9^G): información del movimiento esperado según las características espaciales de la matriz de movimientos detectados.

En la Tabla 4.10 se muestra la matriz de correlación de los descriptores propuestos. Este análisis se realizó para demostrar que los descriptores utilizados para clasificar la calidad de la señal contienen en su mayoría características únicas de la señal y aportan la información necesaria para una clasificación con alta precisión.


Tabla 4.10. Matriz de correlación de descriptores.

Correlación	des_1^G	des_2^G	des_3^G	des_4^G	des_5^G	des_6^G	des_7^G	des_8^G	des_9^G
des_1^G	1								
des_2^G	0.84430	1							
des_3^G	-0.17373	-0.13691	1						
des_4^G	-0.16970	-0.13399	0.45222	1					
des_5^G	0.78457	0.72408	-0.18012	-0.17570	1				
des_6^G	0.00295	0.00415	-0.00622	-0.00358	0.00371	1			
des_7^G	-0.00488	-0.02163	-0.02079	-0.01849	-0.02495	-0.00121	1		
des_8^G	-0.00888	-0.02653	-0.02449	-0.02162	-0.02987	0.00106	0.71260	1	
des_9^G	-0.00280	-0.00473	-0.01330	-0.00568	-0.00490	-0.00002	0.00040	0.00063	1


Inicialmente, se intentó clasificar la señal según su calidad sólo utilizando descriptores antes de la aplicación del estimador WLS, puesto que hallar los movimientos y luego descartarlos es un desgaste computacional que sería preferible evitar. Para demostrar que los descriptores consiguen clasificar y separar de forma adecuada las 2 categorías, se utilizó el algoritmo LDA [28]. Este algoritmo es un reductor de dimensiones que proporciona una interpretación gráfica de como los descriptores propuestos clasifican la información según las categorías conocidas *a priori*.

En un primer intento de clasificación de categorías solo se utilizaron los primeros 5 descriptores propuestos (descriptores antes de la aplicación del WLS) y los resultados se muestran en la Figura 4.6(a), tomando en cuenta que los puntos de color rojo son las proyecciones de los descriptores con buena calidad y los puntos azules son las proyecciones de los descriptores con mala calidad, no se puede separar de forma adecuada la calidad de la señal con esta información insuficiente. Sin embargo, utilizando los descriptores que se generan luego de la aplicación del algoritmo WLS, en la Figura 4.6(b) se observa una separación muy buena de los puntos rojos y azules.

Puesto que el algoritmo LDA demostró que estos descriptores proporcionan información suficiente para la clasificación de calidad, se propone utilizar una red neuronal artificial como bloque clasificador.



(a)



(b)



Figura 4.6. Desempeño del algoritmo LDA (a) LDA para descriptores antes del cálculo de movimiento (b) LDA para descriptores después del cálculo de movimiento.

4.4. Arquitectura y desempeño de la red neuronal artificial

Para clasificar las tramas de señal agrupadas en *stacks* se intentó en un principio utilizar umbrales fijos para cada uno de los descriptores propuestos, sin embargo, este método no generalizaba correctamente la clasificación de calidad como se deseaba.

Con el fin de resolver este problema, se decidió utilizar una red neuronal artificial que aproxime una función que pueda clasificar correctamente la calidad de la señal utilizando los descriptores propuestos.

Como entrada a la red neuronal artificial, se utilizaron los 9 descriptores para cada una de las 120000 tramas sintéticas. Recordemos que estas 120000 tramas están agrupadas en 12 *stacks* de 100 pixeles en azimut por 100 pixeles en rango, en la Figura 4.7 (a) y Figura 4.7 (b) se muestran respectivamente movimientos detectados por el algoritmo WLS para *stacks* con alta correlación espacial y *stacks* con baja correlación espacial.



(a)

(b)

Figura 4.7. Movimientos a detectar por el estimador WLS (a) *Stack* con alta correlación espacial. (b) *Stack* con baja correlación espacial.

Las salidas o *targets* que serán proporcionadas a la red neuronal artificial serán E_{WLS}^M que tiene valores binarios: 1 si el algoritmo WLS detectó correctamente el movimiento sintético a pesar de las distorsiones y 0 si el algoritmo WLS no detectó el movimiento sintético de forma correcta. En la Figura 4.8(a) y en la Figura 4.8(b), se muestra respectivamente, los valores E_{WLS}^G agrupados en una matriz que corresponden a un *stack* con alta correlación espacial y a un *stack* con baja correlación espacial, respectivamente. Estos gráficos son presentados en una vista lateral donde los pixeles de color amarillo corresponden al número 1 (movimiento correctamente detectado) y los pixeles de color azul corresponden al número 0 (movimiento detectado erróneamente).




Figura 4.8. Valores de E_{WLS}^M agrupados en matrices (a) Valores E_{WLS}^M para un *stack* con alta correlación espacial (b) Valores E_{WLS}^M para un *stack* con baja correlación espacial.

Una vez definidas las entradas y salidas de la red neuronal artificial, se diseña la arquitectura de la red. Se utilizó la aplicación *nprtool* de Matlab para generar una red neuronal artificial de reconocimiento de patrones, con 9 unidades de entrada (descriptores propuestos), J neuronas en la capa oculta, función de activación sigmoide hiperbólica tangente para la capa oculta y una salida con función de activación logsig binaria. La arquitectura de la red se muestra en la Figura 4.9.




Figura 4.9. Arquitectura de la red neuronal utilizada para la clasificación de calidad de tramas de señal.

La cantidad de neuronas en la capa oculta fue variada para evaluar la precisión de la red y como mejores con el incremento de unidades de procesamiento. Se entrenaron 6 redes neuronales artificiales de clasificación para $J = 5, 10, 15, 20, 25$ y 30 . Los resultados son presentados en la Figura 4.10 en formato de matriz de confusión para las dos categorías utilizadas: 1 y 0.






Figura 4.10. Matrices de confusión con el desempeño de las redes neuronales de reconocimiento de patrones (a) Capa oculta 5 neuronas (b) Capa oculta 10 neuronas (c) Capa oculta 15 neuronas (d) Capa oculta 20 neuronas (e) Capa oculta 25 neuronas (f) Capa oculta 30 neuronas.

Analizando las matrices de confusión, se observa una mejora en la precisión de la clasificación de calidad a medidas que la red neuronal incrementa sus unidades de procesamiento hasta 20 neuronas, sin embargo, no existe una mejora en el desempeño de la red neuronal artificial de clasificación si se sigue incrementando el número de unidades de procesamiento. Por ello, la arquitectura final de la red utilizada será con $J = 20$, obteniendo una precisión de 90.1% de las muestras proporcionadas a la red.

4.5. Validación con señal real

Una vez que se tiene $f_{rp}(des_1^M, des_2^M, \dots, des_9^M)$ entrenada, se realiza una última prueba de desempeño utilizando señales reales de radar y un experimento controlado para demostrar que la metodología propuesta está funcionando correctamente y detecta los movimientos milimétricos como se espera.

Para la validación del método se realizó el siguiente procedimiento dentro de la serie de datos “expXerem20160216a”, durante los minutos 15 al 45 se utilizó un reflector de canto (también conocido como *corner*) ubicado a 67 metros del radar, con movimiento controlado de aproximadamente 5mm cada 7.5 min en 3 ocasiones. Este movimiento fue realizado sobre una tabla inclinada a 30° , por lo que el movimiento visto por el radar será de $15\cos35^\circ$ mm, es decir, 12.28 mm. En la Figura 4.11 se muestra el reflector sobre la tabla para entender cómo se realizó el movimiento controlado.



Figura 4.11. Reflector o *corner* utilizado para la validación de la metodología.

En la práctica, estos movimientos no fueron efectuados de forma rigurosa, por lo que los movimientos no fueron exactamente de 5mm en desplazamiento, así como tampoco fue preciso en los intervalos de tiempo en los que el reflector estuvo estático.

La Figura 4.12 da un esboce de la dinámica del *corner* reflector. En el eje de las abscisas se tiene el tiempo y en el eje de las ordenadas las fases de la trama convertidas a metros.




Figura 4.12. Tendencia de movimientos del *corner* reflector.

El inicio de la trama de fase corresponde a una región de suelo con problemas de salto de fase, lo cual cambia después que el *corner* es colocado aproximadamente en el minuto 16 de la serie de datos. Al minuto 20 se realiza el primer movimiento de aproximadamente 2.2 mm, el reflector de canto se queda estático por 7 min y realiza un nuevo movimiento de 4.7 mm, nuevamente se queda estático por 10 min para realizar el último movimiento 4.2 mm. Luego de estos movimientos, el reflector es retirado y la trama de fase vuelve a tener problemas de fase doblada.

Finalmente, en la Figura 4.13 se muestra a detalle los desplazamientos hallados por el algoritmo WLS habiéndose descartado los movimientos correspondientes a tramas que no presentan buena calidad.




Figura 4.13. Detalle de las posiciones del reflector a través del experimento de validación.

Los movimientos con buena calidad alcanzan un total de 11.7 mm, siendo el esperado 12.28 mm. Nótese que el inicio de la trama presenta una notable presencia de saltos de fase en donde la red neuronal de reconocimiento de patrones eliminó los movimientos que se puedan haber encontrado en ese lapso de tiempo.

Se obtuvo un error de 0.58 mm en este experimento, lo cual corresponde a un error porcentual del 4.5% del movimiento total, que se encuentra dentro de la tolerancia máxima permitida en el entrenamiento de la red neuronal de reconocimiento de patrones.

Demostrando que la metodología propuesta encuentra movimientos milimétricos y descarta los movimientos cuya calidad no es óptima, se procede a analizar el movimiento de suelos de la zona en análisis.

4.6. Movimientos acumulados de la zona en análisis y correlación con datos pluviométricos

En coordinaciones con el municipio de Duque de Caxias se decidió evaluar la escarpa principal de una ladera de montaña cuyas coordenadas son $22^{\circ}34'6.73''$ S y $43^{\circ}18'35.50''$ W a mayor profundidad ya que el deslizamiento de esta zona podría provocar pérdidas humanas y materiales. Desde ahora, a esta región se le llamará “zona en análisis”.

Se tuvieron 3 series de datos llamadas “expXerem_20160215”, “expXerem_20160216” y “expXerem_20160219”, además de una serie para la validación del método llamada “expXerem_20160216a”.

A las series de datos se les aplicó la metodología propuesta: detección de movimientos utilizando el algoritmo WLS y la eliminación de movimientos producidos por tramas de señal con mala calidad utilizando la red neuronal de reconocimiento de patrones.

Se presenta en la Figura 4.14 se muestran los movimientos, velocidad y aceleración que se hallaron en la serie de datos “expXerem_20160215” para la “zona en análisis”.




Figura 4.14. Movimientos, velocidad y aceleración de la superficie correspondiente a la “zona en análisis” para la serie expXerem_20160215.

Durante esta serie de datos de 13 h de duración, empezando a las 20 UTC-3h el día 15 de febrero del 2016, ocurrió una lluvia ligera entre la tarde y la noche de dicho día, acumulándose 12.2 mm de lluvia. Los movimientos ocurridos son prácticamente nulos, por ende, la velocidad y la aceleración presentan un estado de reposo.

En la Figura 4.15, se presentan los movimientos, velocidad y aceleración calculados para la serie de datos “expXerem_20160216” que consta de 47 h de duración, empezando el día 16 de febrero del 2016 a las 19 UTC-3h.




Figura 4.15. Movimientos, velocidad y aceleración de la superficie correspondiente a la “zona en análisis” para la serie expXerem_20160216.

En este periodo de tiempo ocurrieron dos lluvias, una torrencial de 91 mm de lluvia acumulada pasadas aproximadamente 2 h desde el inicio de la adquisición de datos y otra lluvia fuerte de 7.4 mm de lluvia acumulada en la tarde del día 16 de febrero. Se aprecia que después de la primera lluvia ocurre un ligero movimiento de apenas unos milímetros, sin embargo, después de la segunda lluvia (alrededor de la hora 26 de adquisición), ocurre un movimiento mayor con una velocidad aproximada de 5 mm/h. Nuevamente, alrededor de la hora 37 de adquisición ocurre un nuevo movimiento significativo que alcanza una velocidad de aproximadamente 10 mm/h. Contabilizando todos los movimientos ocurridos en esta serie de datos se obtienen 25 mm de desplazamiento acumulado.

Finalmente, en la Figura 4.16 se muestran los movimientos, velocidad y aceleración que se hallaron en la serie de datos “expXerem_20160219”. Esta serie tuvo un periodo de adquisición de 46 h empezando el día 19 de febrero del 2016 a las 15 UTC-3h.




Figura 4.16. Movimientos, velocidad y aceleración de la superficie correspondiente a la “zona en análisis” para la serie expXerem_20160219.

Durante esta ultima serie de datos ocurrieron también 2 lluvias. La primera acumuló 20 mm de lluvia que se inició a las 18 UTC-3h del día 19 de febrero del 2016 y una segunda precipitación que acumuló 35.2 mm de lluvia empezando a las 19 UTC-3h del día 20 de febrero del 2016. Se obtuvo una velocidad alta de casi 20 mm/h durante la primera lluvia de esta serie y otra velocidad alta de aproximadamente 14 mm/h alrededor de la hora 13 de adquisición. Un tercer movimiento en en dirección contraria ocurre alrededor de la hora de adquisición 25, que corresponde a la segunda lluvia ocurrida durante esta serie. Los movimientos ocumulados obtenidos durante las 46 h fueron de 47 mm.

Observando todo el experimento, se analiza que luego de la primera lluvia ocurrida el día 16 de febrero del 2016, empiezan los movimientos en la “zona en análisis”, y mientras más precipitaciones existen en los días previos, transcurre menos tiempo entre el inicio de la lluvia y el inicio de los movimientos, así mismo, la cantidad de movimiento ocurrido es progresivamente mayor en cada serie.

Para observar las consecuencias de estos movimientos se fotografió un muro ubicado en 22°34'7.1"S y 43°18'38.10"W. Se observa en la Figura 4.17, los daños ocasionados en este muro cerca a la “zona en análisis”.



Figura 4.17. Muro dañado por los movimientos ocurrido en la “zona en análisis”.

Se muestran a continuación los movimientos para toda el área comprendida en 1 km desde la posición del radar, para el tipo de escaneo circular. En la Figura 4.18 se muestran los movimientos acumulados durante toda la serie expXerem_20160215, en la Figura 4.19 se muestran los movimientos acumulados durante toda la serie expXerem_20160216 y en la Figura 4.20 todos los movimientos acumulados durante la serie expXerem_20160219.

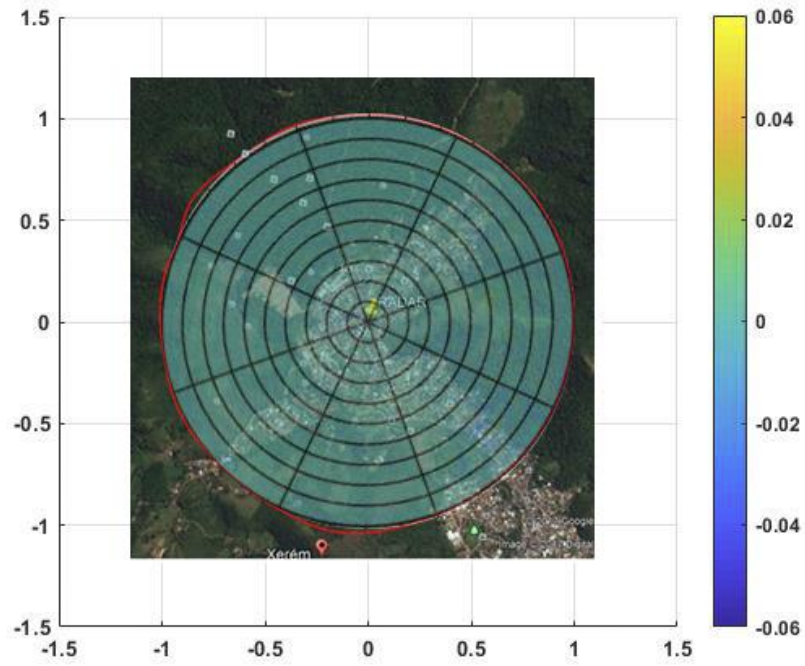


Figura 4.18. Movimientos acumulados para un 1 km de alcance para la serie expXerem_20160215.




Figura 4.19. Movimientos acumulados para un 1 km de alcance para la serie expXerem_20160216.




Figura 4.20. Movimientos acumulados para un 1 km de alcance para la serie expXerem_20160219.

Se observa que las zonas con mayor movimiento corresponden a regiones montañosas con alto índice de vegetación.

La escarpa principal en análisis presenta movimientos desde 25 mm/día hasta 47 mm/día. Existen diferentes umbrales para alerta de un posible deslizamiento en [29], por ejemplo, en Val Pola, el umbral es de 74-77 mm/día, para Vaiont, 207-923 mm/día y para Chuquicamata el umbral es una velocidad máxima de 50 mm/día. Estas diferencias se deben a la complejidad geológica de cada zona estudiada. En el caso de Xerém, no ocurrió un derrumbe o deslizamiento de suelos importante, sin embargo, al estar cerca de una zona urbana el riesgo es alto y, consecuentemente, otros estudios geológicos deben ser realizados para determinar un umbral de alerta inminente de deslizamiento.

4.6.1. Contrastación de la hipótesis general

Se caracterizó la geodinámica de una superficie utilizando señales de radar de banda X. El objetivo del método propuesto es monitorear las escarpas con riesgos de deslizamientos y proporcionar información haciendo el cálculo de movimientos, en base al análisis y procesamiento de las señales de radar adquiridas.

Se realizaron campañas de adquisición de señal en áreas con riesgo en Xerém, distrito de Duque de Caxias, estado de Río de Janeiro. Las áreas donde el radar indica

que ocurrió un movimiento importante, en relación al entorno de la región monitoreada, fueron consideradas como anómala. El análisis detallado sobre el comportamiento geodinámico de esta área fue presentado en el Capítulo IV, donde se constató que las precipitaciones incrementan la cantidad de movimiento en las superficies bajo estudio. La zona con movimiento anómalo presentó movimientos de hasta 47 mm en el último día de adquisición de señal. Comparado con umbrales de alarma publicado en [29], se constató que este proceso de era anómalo. Para verificar, se realizó un análisis de campo en la zona con movimiento anómalo, esta se encontraba cerca de un muro de contención, el cual está curvado y agrietado como se mostró en la Figura 4.17.

4.6.2. Contrastación de las hipótesis específicas

Con respecto a la primera hipótesis específica, se evidenció que el error porcentual medio más bajo presentado por los estimadores estudiados en este trabajo de tesis lo presentó el estimador de movimiento WLS. El error porcentual medio del estimador WLS, con 5% de tolerancia de detección de movimiento, fue de 49.01% frente a los errores porcentuales de cálculo de movimiento de 97.19% y 98.63% de los estimadores MS y XY-T respectivamente.

Para contrastar la segunda hipótesis específica se comparó el tiempo de procesamiento utilizado por el método propuesto y el tiempo de apilamiento o *staging*. En este caso, el tiempo de procesamiento por el algoritmo WLS, para un tiempo de integración de 3.5 min es de 1.16 min obteniendo una razón entre ellos de 0.34. Este tiempo garantiza la aplicación del método en tiempo real.

Por último, la tercera hipótesis específica se verifica con el 90.1% de precisión obtenido en la clasificación de calidad de señal utilizando la red neuronal artificial con 20 neuronas en la capa intermedia. Cabe resaltar que la elección de los 9 indicadores y el análisis de la información contenida ha sido parte de estudio de este trabajo de tesis.

CONCLUSIONES

El trabajo de tesis presentado tiene como objetivo principal caracterizar la dinámica de suelos de un territorio de hasta 1 km de alcance utilizando señales de radar de apertura sintética, montado en el suelo, y para ello se plantea primero encontrar la calidad mínima de señal con la que un estimador detecte satisfactoriamente el movimiento de masas terrestres. Bajo esta premisa, surgieron tres objetivos específicos: Hallar el mejor estimador de movimiento para el tipo de señal adquirida, hallar el tiempo de integración óptimo en el que la señal pueda ser procesada para el cálculo de movimientos y operar en tiempo real; y finalmente, desarrollar una etapa de clasificación de calidad de señal para garantizar que los movimientos calculados son efectivamente desplazamientos de suelos y no producto de las distorsiones de señal.

En el contexto del primer objetivo específico, se propusieron tres estimadores de fase de movimiento de masas terrestres: Media simple, Media espacio-temporal y estimador por Mínimos cuadrados ponderados. El desempeño de cada uno fue distinto para condiciones de ruido y distorsión de fase diferentes. El estimador WLS fue el que mejor desempeño obtuvo, presentando un error porcentual de 49%, utilizando la información sintética (contra 98.31% para MS y 98.64% para XY-T), a pesar de todas las distorsiones de señal que existen y corrompen la información adquirida. Esto se debe a que se utiliza una ponderación según la coherencia de cada pixel en un *stack* para sus vecinos espaciales y la correlación que tiene este mismo pixel durante el intervalo de tiempo de integración.

En el contexto del segundo objetivo específico, para el cálculo del tiempo de integración óptimo se utilizaron señales sintéticas para observar como el algoritmo WLS se desempeñaba mientras se iba incrementando la duración de la señal adquirida. Para una integración de 3.5 min, el tiempo de procesamiento del algoritmo WLS es inferior al tiempo de generación de *stack* y, tomando en cuenta que, en el método propuesto, además del cálculo de movimiento existe una etapa de clasificación de señal, este no se podía incrementar más. Incrementar el tiempo de integración conlleva un tiempo de procesamiento demasiado grande que no permitiría que la aplicación del método propuesto en este trabajo de tesis sea utilizada en tiempo real.

Para la clasificación de la señal según la calidad de la información, de acuerdo con el tercer objetivo específico, se propusieron 9 descriptores que se aplican a cada trama de señal en el tiempo cuando estas son agrupadas en *stacks*. Se obtuvo un 90.1% de precisión utilizando una red neuronal artificial de clasificación con 20 neuronas en la capa oculta; esta cantidad de neuronas fue determinada de forma heurística.

Por último, se concluye que la estimación de movimientos de masa terrestre utilizando señales de radar de apertura sintética debe ser efectuada utilizando un estimador de fase que se adapte a las características espaciales, temporales y distorsiones de ruido propias de la región en estudio. Los filtros lineales no logran adaptarse a las distorsiones de fase que se pueden encontrar en este tipo de señales y por ello, no son los más adecuados.

En una zona de la ciudad de Xerém fue posible caracterizar los movimientos de masa terrestre (y conocer su dirección radial) utilizando el estimador de fase WLS con un tiempo de integración de 3.5 min y los 9 descriptores propuestos para clasificar la calidad de la señal, y así analizar la relación de los movimientos con los datos pluviométricos de este territorio durante el periodo de las campañas de adquisición de señal.

RECOMENDACIONES

Luego de la propuesta del estimador WLS para caracterizar los movimientos de masa terrestre utilizando señales de radar de apertura sintética montado en el suelo, quedan algunas recomendaciones para posibles investigaciones a futuro.

Uno de los inconvenientes más grandes en la caracterización de movimientos es la calidad de la señal. La distorsión de ruido debido a la baja resolución espacial puede ocasionar interferencias destructivas o constructivas y es por ello que se recomienda que la resolución espacial sea la máxima posible, tanto en azimut como en rango. Otras distorsiones de fase común se ocasionan por los saltos de fase por el efecto de fase doblada (*phase unwrapping*), un análisis más a fondo de este efecto podría maximizar la cantidad de información efectiva y no descartarlos como se hace en esta tesis.

Se propusieron 9 descriptores de calidad para clasificar las tramas de señales como aptas y no aptas para la validez del movimiento hallado. De estos descriptores, 4 se hallan luego de aplicar el algoritmo WLS, es decir, que de todas maneras se hace el cálculo de movimiento de las tramas con mala calidad y luego son descartadas. Esto ocasiona un esfuerzo computacional que podría ser evitado con la elección de otros descriptores. Las elecciones de otros descriptores también podrían mejorar la precisión de 90.1% que tiene el clasificador utilizado en esta tesis.

Finalmente, el estimador WLS es demasiado costoso computacionalmente y sería interesante optimizar su desempeño, ya sea por mejoras en la algoritmia o su adaptación para un procesamiento en paralelo.

REFERENCIAS BIBLIOGRÁFICAS

- [1] S. Villacorta, L. Fidel, B. Zavala Carrion, . 2004. "Mapa de Susceptibilidad Por Remoción En Masa de Suelos y Rocas." *Revista de la Asociación Geológica Argentina* 69(3): 393–99.
<http://snet.gob.sv/ver/geologia/amenaza+deslizamientos/>.
- [2] MINAM. 2015. "Mapa de Susceptibilidad Física Del Perú." *Dirección General de Ordenamiento Territorial*: Lima-Peru.
- [3] Di Martire, Diego et al. 2014. "Comparison between Differential SAR Interferometry and Ground Measurements Data in the Displacement Monitoring of the Earth-Dam of Conza Della Campania (Italy)." *Remote Sensing of Environment* 148: 58–69. <http://dx.doi.org/10.1016/j.rse.2014.03.014>.
- [4] McHugh, Edward L., Jami Dwyer, David G. Long, and Charles Sabine. 2002. "Applications of Ground-Based Radar To Mine Slope Monitoring." *Safety And Health* (April).
- [5] Griffith S., Akpeko Gasonoo, and Isaac K. E. Ampomah. 2013. "On the Performance of Filters for Reduction of Speckle Noise in SAR Images off the Coast of the Gulf of Guinea." 1(4): 41–50. <http://arxiv.org/abs/1312.2383>.
- [6] Sosnovsky, Andrey, and Victor Kobernichenko. 2015. "Algorithm of Interferometric Coherence Estimation for Synthetic Aperture Radar Image Pair." *CEUR Workshop Proceedings* 1452: 172–76
- [7] Ye, Wei, and Tat Soon Yeo. 1999. "Weighted Least-Squares Estimation of Phase Errors for SAR/ISAR Autofocus." *IEEE Transactions on Geoscience and Remote Sensing* 37(5 II): 2487–94.
- [8] Bamler, Richard, and Philipp Hartl. 1998. "Synthetic Aperture Radar Interferometry." *Inverse Problems* 14(4): R1–54.
- [9] Chaturvedi, Pratik, Shikha Srivastava, and Neetu Tyagi. 2016. "Prediction of Landslide Deformation Using Back-Propagation Neural Network." *2015 IEEE Workshop on Computational Intelligence: Theories, Applications and Future Directions, WCI 2015*: 1–5. [10] A. Ferretti, C. Prati, and F. Rocca, "Permanent scatterers in SAR interferometry," *IEEE Trans. Geosci. Remote Sens.*, vol. 39, no. 1, pp. 8–20, 2001.

- [10] Ferretti, Alessandro, Claudio Prati, and Fabio Rocca. 2001. "Permanent Scatterers in SAR Interferometry." *IEEE Transactions on Geoscience and Remote Sensing* 39(1): 8–20.
- [11] Osso, Corporación. 2008. "PERÚ Análisis de Base de Datos de Pérdidas Por Desastres En Perú." *Creación, actualización y/o homogeneización de inventarios de desastres por eventos históricos y cotidianos a nivel de la Subregión Andina*.
- [12] Florentino, André, Saúl Charapaqui, César De La Jara, and Marco Milla. 2017. "Implementation of a Ground Based Synthetic Aperture Radar (GB-SAR) for Landslide Monitoring: System Description and Preliminary Results." *Proceedings of the 2016 IEEE 23rd International Congress on Electronics, Electrical Engineering and Computing, INTERCON 2016*: 3–8.
- [13] Buemi, Elena. 2012. "Tratamiento de Imágenes de Radar de Apertura Sintética Mediante Filtros Stack On." *Universidad de Buenos Aires*.
- [14] Salas, Rodrigo. 2004. "Redes Neuronales Artificiales." *Universidad de Valparaíso. Departamento de Computación*: 1–15.
- [15] M. Rubiolo, "Desarrollo de nuevos modelos y algoritmos basados en redes neuronales para tareas de minería de datos," UNIVERSIDAD TECNOLÓGICA NACIONAL, 2014.
- [16] Bishop, Christopher M. 2006. 1 Information Science and Statistics *PATTERN RECOGNITION AND MACHINE LEARNING*. 1st ed. eds. M. Jordan, J. Kleinberg, and B. Schoelkopf. Yellowstone: Springer.
- [17] Kim, Tai Hoon. 2010. "Pattern Recognition Using Artificial Neural Network: A Review." *Communications in Computer and Information Science* 76 CCIS: 138–48.
- [18] Schowengerdt, Robert A. 2012. Remote Sensing: Models and Methods for Image Processing: Second Edition *Remote Sensing: Models and Methods for Image Processing: Second Edition*.
- [19] Cruden, D. M. 1991. "A Simple Definition of a Landslide." *Bulletin of the International Association of Engineering Geology* 43: 27–29.
- [20] Peebles, Peyton Z. 2009. *Probability, Random Variables and Random Signal Principles*. 2nd ed. Singapore.
- [21] Berardino, P., G. Fornaro, R. Lanari, and E. Sansosti. 2002. "A New Algorithm for Surface Deformation Monitoring Based on Small Baseline Differential SAR

- Interferograms." *IEEE Transactions on Geoscience and Remote Sensing* 40(11): 2375–83.
- [22] Crosetto, M. et al. 2013. "Interferometric SAR Monitoring of the Vallcebre Landslide (Spain) Using Corner Reflectors." *Natural Hazards and Earth System Science* 13(4): 923–33.
- [23] Kimura, Hiroshi, and Y Yamaguchi. 2000. "Detection of Landslide Areas Using Satellite Radar Interferometry." *Photogrammetric Engineering & Remote Sensing* 66(3): 337–44. 344.pdf.
- [24] Wiesmann, Andreas, Charles Werner, Tazio Strozzi, and Urs Wegmüller. 2000. "Measuring Deformation and Topography With a Portable Radar Interferometer." : 1–9. and Topography With a Portable Radar Interferometer," pp. 1–9, 2000.
- [25] Luzi, G. et al. 2004. "Ground-Based Radar Interferometry for Landslides Monitoring: Atmospheric and Instrumental Decorrelation Sources on Experimental Data." *IEEE Transactions on Geoscience and Remote Sensing* 42(11): 2454–66.
- [26] De Macedo, Karlus Alexander Câmara et al. 2017. "A Compact Ground-Based Interferometric Radar for Landslide Monitoring: The Xerém Experiment." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10(3): 975–86.
- [27] V. Kurkova, "Kolmogorov's theorem and multilayer neural networks," *Neural Networks*, vol. 5, no. 3, pp. 501–506, 1992.
- [28] Xanthopoulos, Petros, Panos M. Pardalos, and Theodore B. Trafalis. 2013. "Linear Discriminant Analysis." In , 27–33. papers3://publication/uuid/D2E946DE-1190-4ADC-AE33-A86CC8A7B728.
- [29] Hungr, O., J. Corominas, and E. Eberhardt. 2005. "State of the Art Paper #4, Estimating Landslide Motion Mechanism, Travel Distance and Velocity." *Landslide Risk Management* (February 2017): 99–128.
- [30] Crosetto, M & Crippa, B & Biescas, Erlinda & Monserrat, O & Agudo, Marta. 2005. State-of-the-Art of Land Deformation Monitoring Using Differential SAR Interferometry.