

Identificación de bosques invadidos por Ligustrum lucidum W.T. Aiton en el centro de Córdoba, mediante datos ópticos y SAR

Por ***María Paula Alvarez***

Presentado ante la Facultad de Matemática, Astronomía y Física y el Instituto de Altos Estudios Espaciales Mario Gulich como parte de los requerimientos para la obtención del grado de

MAGISTER EN APLICACIONES DE INFORMACIÓN ESPACIAL

UNIVERSIDAD NACIONAL DE CÓRDOBA

Noviembre, 2020

©IG-CONAE 2020

©FaMAF-UNC 2020

DIRECTORA

Dra. Anabella Ferral

Instituto Gulich - Comisión Nacional de Actividades Espaciales - Universidad Nacional de Córdoba,
Córdoba, Argentina

CO-DIRECTOR

Dr. Marcos Sebastián Karlin

Facultad de Ciencias Agropecuarias - Universidad Nacional de Córdoba, Córdoba, Argentina



Esta obra está bajo una licencia Attribution-NonCommercial-ShareAlike 4.0 International
(CC BY-NC-SA 4.0)

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Agradecimientos

A Silvina, Mónica y Miguel por confiar en mí desde el principio y mostrarme esta maravillosa oportunidad.

A mi familia y amigos, que siempre creen en mí y me alientan a hacer lo que me gusta. Sobre todo a mis mejores docentes Normi y Jorge, los más aplicados, comprensivos y apasionados.

Al Ema, mi tesoro, por apoyarme y seguirme (*literalmente*) en todo lo que emprendo.

A los Maestros por hacerme reír muchísimo, enseñarme tantas cosas y sostenernos en estos años tan intensos.

Al Estado Argentino, que por medio de CONAE, el Instituto Mario Gulich y la Facultad de Matemática, Astronomía, Física y Computación-UNC me permitieron cursar esta maestría y siguen apostando a esta experiencia. Y a las personas que lo conforman, gracias por creer en la Educación Pública!! En especial, a aquellos que desinteresadamente me ayudaron a resolver inquietudes de la tesis: Docentes de la MAIE, Tefi, Exe, Xime, Juan y Marcelo.

Al Estado Italiano, la Agenzia Spaziale Italiana y la EURAC, en especial a Claudia y Alex, por la posibilidad de realizar la pasantía que generó aportes tan importantes para mi tesis. También a mis compañeros Santi, Jonito y Euge por ser mi familia durante ese tiempo.

A mis directores Anabella y Marcos.

A Riqui, Amanda, Javi, Marcos y los demás cuenqueros con los que aprendí y me divertí tanto.

Resumen

Las perturbaciones producidas por los cambios en la cobertura terrestre favorecen la proliferación de especies leñosas exóticas invasoras. En el centro de la Provincia de Córdoba, estas especies modifican el ciclo del agua, contribuyen a la pérdida de biodiversidad, y modifican los ciclos de los nutrientes. *Ligustrum lucidum* W.T. Aiton o Siempreverde es la especie arbórea exótica invasora más importante de esta región.

En esta tesis, se evaluaron series temporales de datos derivados de imágenes ópticas (*Reflectancia e Índice Normalizado de Vegetación (NDVI)*) y SAR (*Coefficiente de retrodispersión (CR)* y *Coherencia interferométrica (Coh)*). Luego fueron utilizadas como entradas en algoritmos de clasificación para diferenciar bosques nativos invadidos por *Ligustrum lucidum* W.T. Aiton en el centro de Córdoba, Argentina. Los algoritmos empleados fueron: Árbol de decisión (AD), Support Vector Machine (SVM), Random Forest (RF) y Análisis Discriminante Lineal (ADL).

Las especies arbóreas presentes en los bosques nativos analizados (*Sebastiania commersoniana* (Baill.) L.B. Sm. & Downs *Lithraea molleoides* (Vell.) Engl.) y la exótica invasora *L. lucidum* mostraron características fisiológicas, morfológicas y estructurales que se manifestaron en las series temporales evaluadas. Las clasificaciones de estas series temporales permitieron diferenciar bosques nativos invadidos por *L. lucidum* con distintos niveles de precisión en el centro de Córdoba, Argentina. Los mejores resultados de clasificaciones se obtuvieron al clasificar series de temporales de Coh.

Se requieren nuevos estudios para probar la robustez de los clasificadores. Se propone además profundizar en el estudio de series temporales de Coh mediante el uso de otros sensores con diferente longitud de onda, resolución espacial y resolución temporal; el análisis de las mismas para diferentes estratos de vegetación, afectados por disturbios, con diferentes usos y manejo; y la evaluación de diferentes tamaños de ventana de estimación de la Coh.

Palabras clave: *InSAR, Clasificación de bosques, Inteligencia Artificial, Sentinel-1, Sentinel-2.*

Abstract

Disturbances produced by land cover changes favour alien woody invasive species proliferation. In the central semiarid region of Argentina, alien woody invasive species modify the water cycle, reduce biodiversity and alter the nutrient cycles. One of the most predominant of them is the glossy privet (*Ligustrum lucidum* W.T.Aiton).

In this thesis, temporal series derived from optical data (*Reflectance and NDVI*) and SAR data (*Backscattering coefficient (CR) and Interferometric coherence (Coh)*) were evaluated. Then, these were employed as vector inputs on classification algorithms to differentiate native forests invaded by *Ligustrum lucidum* W.T. Aiton. Decision trees (AD), Support Vector Machine (SVM), Random Forest (RF) and Linear discriminant analysis (ADL) classifiers were employed.

The woody species of the native forests analyzed (*Sebastiania commersoniana* (Baill.) L.B. Sm. & Downs and *Lithraea molleoides* (Vell.) Engl.) and the woody exotic invader *L. lucidum* showed physiological, morphological and structural differences that could be observed on the evaluated temporal series. Classifications of these temporal series has allowed to differentiate between forests invaded by *L. lucidum* with different levels of accuracy. The best results were obtained classifying Interferometric coherence temporal series.

New studies are required to test the robustness of the classifiers. Therefore it is proposed to study the Interferometric Coherence temporal series through: data analysis of other SAR sensors with different wavelength, spatial and temporal resolution; analysis in strata of vegetation under different uses with different degrees of disturbances; and the evaluation of different size windows for the estimation of the coherence.

Keywords: InSAR, Forest classifications, Artificial Intelligence, Sentinel-1, Sentinel-2

Índice de Contenidos

1. Introducción	1
1.1. Objetivos	2
1.1.1. General	2
1.1.2. Específicos	2
2. Marco Teórico	3
2.1. Antecedentes	3
2.2. Vegetación invasora	4
2.2.1. Leñosas invasoras en el área de estudio	4
2.3. Datos ópticos	8
2.3.1. Vegetación en la región del visible e infrarrojo	8
2.3.2. Imágenes de Sentinel 2 MSI	10
2.4. Datos SAR	10
2.4.1. Vegetación en imágenes SAR	12
2.4.2. Coherencia interferométrica	13
2.4.2.1. Fuentes de decorrelación	14
2.4.2.2. Aplicaciones de la coherencia	15
2.4.2.3. Pasos para obtener la estimación de coherencia	16
2.4.3. Imágenes Sentinel 1 IW SLC	18

2.5.	Separabilidad de clases	19
2.5.1.	Análisis marginal	19
2.5.1.1.	Gráficos de caja y bigotes o Boxplots	19
2.5.1.2.	Pruebas de diferencias de medias	21
2.5.2.	Análisis de estructura temporal	23
2.6.	Clasificaciones	24
2.6.1.	Clasificaciones con Series Temporales	25
2.6.2.	Algoritmos de clasificación	26
2.6.2.1.	Árbol de decisión	26
2.6.2.2.	Random Forest	26
2.6.2.3.	Support Vector Machine	26
2.6.2.4.	Análisis discriminante	27
2.6.3.	Precisión de las clasificaciones	28
2.6.3.1.	Matriz de confusión	28
2.6.3.2.	Medidas de precisión	28
3.	Área de estudio	30
3.1.	Vegetación	31
3.2.	Clima	33
3.3.	Suelo	33
4.	Materiales y Métodos	36
4.1.	Datos de campo	36
4.2.	Descarga y procesamiento de imágenes	39
4.2.1.	Datos SAR	39
4.2.1.1.	Coefficiente de retrodispersión	40
4.2.1.2.	Coherencia	42
4.2.2.	Datos ópticos	44
4.2.2.1.	Cálculo de NDVI	45
4.3.	Análisis descriptivo de series temporales	46
4.4.	Separabilidad de clases	47

4.4.1.	Analisis marginal	47
4.4.2.	Analisis de estructura temporal	48
4.5.	Clasificaciones	48
4.5.1.	Árboles de decisión	49
4.5.2.	Random Forest, Support Vector Machine y Análisis discriminante lineal	50
4.6.	Interpretación geográfica de las clasificaciones	51
4.7.	Re-validación de resultados	52
5.	Resultados y discusión	53
5.1.	Análisis descriptivo de series temporales	53
5.1.1.	Coherencia interferométrica	53
5.1.2.	Coefficiente de Retrodispersión en dB	56
5.1.3.	NDVI	58
5.2.	Separabilidad de clases	59
5.2.1.	Análisis marginal	59
5.2.2.	Analisis de estructura temporal	62
5.3.	Clasificaciones	65
5.3.1.	Árboles de decisión	66
5.3.2.	Random Forest y Support Vector Machine	67
5.3.3.	Análisis discriminante	71
5.4.	Interpretación geográfica de las clasificaciones	75
5.5.	Re-validación de resultados	77
6.	Conclusiones	80
	Anexos	88
A.	Medidas resumen de series temporales	88
B.	Códigos Python	90
C.	Estadística de diferencias entre clases por fechas	95

Índice de figuras

2.1. Firma espectral de vegetación	9
2.2. Profundidad de penetración diferentes longitudes de onda	13
2.3. Estimador de coherencia $ \hat{\gamma} $ y varianza del estimador $\sigma_{ \hat{\gamma} }$ en función del número de looks (L) y del valor real de coherencia $ \gamma $	14
2.4. Modo de adquisición TOPSAR Sentinel 1	19
2.5. Elementos de un boxplot: Q1, Q1, IQR, mediana, bigotes, outliers	20
3.1. Reserva Natural de la Defensa La Calera (RNDLC)	30
3.2. Climograma estación Observatorio	33
3.3. Unidades taxonómicas de suelo de la RNDLC	34
4.1. Ubicación de sitios de muestreo	37
4.2. Fotografías clase <i>lluc</i>	38
4.3. Fotografías clase <i>nat</i>	38
4.4. Fotografías clase <i>mix</i>	39
4.5. Diagrama de enmascarado por sombra o inversión (<i>layover</i>)	41
4.6. Diagrama de flujo Coeficiente de Retrodispersión	42
4.7. Diagrama de flujo estimación de coherencia interferométrica	43
4.8. Pruebas de hipótesis de diferencias de medias	47
4.9. Diagrama de flujo de clasificador de árbol de decisión	49

5.1. Series temporales de Coherencia interferométrica	55
5.2. Series temporales de Coeficiente de retrodispersión	56
5.3. Serie temporal NDVI	58
5.4. Boxplots para el estadístico <i>media</i> de las series temporales anuales por clases	60
5.5. Boxplots para el estadístico <i>desvío estándar</i> de las series temporales anuales por clases	61
5.6. Distancia de Bray Curtis entre pares de clases por variable	63
5.7. Coeficiente de correlación temporal entre pares de clases por variable . . .	64
5.8. Coeficiente de disimilitud D con k=1 entre pares de clases por variable . . .	65
5.9. Clasificación obtenida con DT1	66
5.10. Clasificación obtenida con RF - Coh VV	68
5.11. Clasificación obtenida con SVM - CR VV	69
5.12. Clasificación obtenida con RF - NDVI+Coh VH	70
5.13. Clasificación obtenida con RF - NDVI+Coh VV	71
5.14. Espacio transformado ADL	72
5.15. Clasificación obtenida con ADL - NDVI+Coh VH	73
5.16. Precisión Global (%)	74
5.17. Índice Kappa	74
5.18. Vías de escurrimiento, red vial, áreas urbanas y pendientes	75
5.19. Histograma de clases	77
5.20. Proporción de píxeles a menos o más de 100m de vías de escurrimiento . . .	77
5.21. Proporción de píxeles a menos o más de 600m de áreas urbanas	77
5.22. Proporción de píxeles sobre áreas con menos o más de 25% de pendiente . .	77
5.23. Nuevos sitios de muestreo	78

Índice de tablas

2.1. Caracteres diferenciales <i>L. lucidum</i> , <i>L. molleoides</i> , <i>S. commersoniana</i>	7
2.2. Características de bandas de los sensores MSI a bordo de Sentinel-2	10
3.1. Unidades cartográficas RNDLC	33
4.1. Datos de campo: clases	37
4.2. Imágenes S1B seleccionadas	40
4.3. Intervalos de estimación de coherencia interferométrica	42
4.4. Imágenes S2 seleccionadas	45
4.5. Combinaciones de variables y umbrales en árbol de decisión	50
4.6. Series temporales de entrada	51
4.7. Imágenes seleccionadas	51
5.1. Validación RF CohVV+NDVI	78
5.2. Validación ADL CohVH+NDVI	79
5.3. Validación AD1	79
A.1. Medidas resumen de series temporales. Clase <i>lluc</i>	88
A.2. Medidas resumen de series temporales. Clase <i>nat</i>	89
A.3. Medidas resumen de series temporales. Clase <i>mix</i>	89
C.1. Diferencias entre clases - Coh VH	96

C.2. Diferencias entre clases - Coh VV	97
C.3. Diferencias entre clases - CR VH	99
C.4. Diferencias entre clases - CR VV	101
C.5. Diferencias entre clases - NDVI	103

Acrónimos

Coh Coherencia interferométrica

VH Polarización VH

VV Polarización VV

HV Polarización HV

HH Polarización HH

CR Coeficiente de retrodispersión

NDVI Índice Normalizado de Vegetación

RNDLC Reserva Natural de la Defensa La Calera

SAR Radar de Apertura Sintética

SNAP Sentinel Application Platform

PG Precisión Global

K Índice Kappa

InSAR Interferometría SAR

DEM Modelo digital de elevación

SVM Support Vector Machine

RF Random Forest

ADL Análisis Discriminante Lineal

AD Árbol de decisión

Glosario

Nadir: Es la intersección entre la vertical del observador y la esfera celeste.

Dehiscente: Que presenta dehiscencia: apertura espontánea de una estructura vegetal, una vez llegada su madurez, para liberar su contenido.

Radiación directa: es la que llega a la superficie terrestre directamente del sol.

Radiación difusa: es aquella que llega a la superficie terrestre con una desviación en su dirección original a causa de la interacción con moléculas de la atmósfera.

Mesófilo esponjoso: mesófilo es un conjunto de células que forma el interior de las hojas. Se encuentra entre las epidermis. En el mesófilo esponjoso, estas células son de forma irregular y tienen grandes espacios intracelulares.

Línea de base temporal: En Interferometría SAR, es el tiempo entre la adquisición de las dos imágenes.

Xerófilo: adjetivo aplicado a especies vegetales adaptadas a la vida en un medio seco.

Dirección de acimut: en SAR, dirección de avance del satélite.

Swath: ancho de barrido, o ancho de la superficie iluminada por un sensor.

Multilooking: promedio de sub-imágenes, estadísticamente independientes, correspondientes a la misma escena. Mejora la incerteza radiométrica a expensas de pérdida de resolución espacial.

DEM: Modelo digital de elevación. Es una representación visual y matemática de los valores de altitud de la superficie terrestre con respecto a un sistema de referencia concreto, generalmente el nivel medio del mar.

Zoocoria: Modo de dispersión de propágulos en el que el agente dispersor es un animal.

Rodal: Una comunidad de árboles, los cuales son uniformes en composición, tamaño, edad o condición de especies y son manejados como una sola unidad.

Grupo funcional: grupo de organismos con similar respuesta al ambiente, o similares efectos sobre el ecosistema.

CAPÍTULO 1

Introducción

Los cambios en la cobertura de suelo modifican los ciclos naturales al introducir variables físicas, químicas y biológicas que alteran el equilibrio estacionario del sistema y causan la pérdida de biodiversidad a escala global. Para remediar estos impactos, los sistemas requieren grandes cantidades de energía. Algunas perturbaciones producidas por los cambios en la cobertura terrestre favorecen la proliferación de especies leñosas exóticas invasoras.

Las especies exóticas invasoras pueden modificar el ciclo del agua [1] [2] [3] [4], contribuir a la pérdida de biodiversidad [3] [4] y alterar los ciclos de nutrientes [2] [3].

Varios investigadores [5][6] proponen que el incremento de la ocurrencia de crecientes repentinas o largos períodos de sequía en cuencas de montaña está relacionado con el reemplazo de vegetación arbórea nativa por especies exóticas invasoras en la porción superior de las cuencas. En este contexto, la calidad de agua en los reservorios puede verse afectada por fenómenos de escorrentía que arrastran sedimentos y favorecen la depositación de los mismos en cursos de agua debido a una disminución en la retención de suelo.

Para el manejo de recursos forestales es necesaria la implementación de programas de monitoreo continuo y operativo. Para este fin, muchas técnicas han sido utilizadas a nivel mundial, e incluyen muestreos de campo, sensores automáticos de campo y sensores remotos. Los muestreos de campo son costosos y muchas veces no son aplicables en algunas áreas debido a sus condiciones geográficas o a restricciones legales de ingreso. En este marco, el sensado remoto es una alternativa rápida, repetible y de bajo costo [7] que puede ser utilizada en áreas de difícil acceso [8], y con la garantía de monitoreos periódicos.

En la región geomorfológica de Sierras Chicas, donde se encuentra el área de estudio, el monitoreo de presencia de especies arbóreas invasoras y su expansión fue llevada a cabo por Hoyos et. al [4] y Gavier-Pizazzo et. al [9], respectivamente, mediante sensores remotos ópticos. No se encontraron estudios que utilicen datos de coherencia interferométrica para la clasificación de tipos de bosques por otro criterio que no sea el de caducidad de sus hojas.

En los últimos años, imágenes satelitales SAR y ópticas están disponibles de manera gratuita, como así también programas robustos de procesamiento, que se volvieron indispensables para los programas de monitoreo forestal. Técnicas de monitoreo forestal basadas en imáge-

nes ópticas están siendo utilizadas, mientras que no así las basadas en imágenes SAR. Es por ello que con esta tesis se pretende hacer contribuciones en este campo.

1.1. Objetivos

1.1.1. General

Evaluar metodologías para diferenciar la especie *Ligustrum lucidum* W.T. Aiton de especies arbóreas nativas en el centro de Córdoba, mediante el análisis de datos SAR y ópticos.

1.1.2. Específicos

- Caracterizar a las especies *Ligustrum lucidum* y a otras especies nativas en el área de estudio
- Reconocer caracteres fisiológicos, morfológicos y estructurales en las especies *Ligustrum lucidum* y en otras especies nativas presentes que puedan originar diferencias en la respuesta espectral SAR y óptica
- Evaluar técnicas de clasificación supervisadas que permitan diferenciar rodales invadidos por *Ligustrum lucidum*, mediante datos ópticos y SAR
- Verificar la exactitud de las imágenes obtenidas en las clasificaciones mediante campañas de muestreo a campo.

2.1. Antecedentes

En la región geomorfológica de Sierras Chicas, el monitoreo mediante sensores remotos ópticos de la invasión de bosque nativo por la especie *Ligustrum lucidum* fue llevada a cabo por Hoyos et al. [4] y Gavier-Pizazzo et al. [9]. En estos estudios lograron diferenciar bosques dominados por *Ligustrum lucidum* de bosques dominados por especies nativas con precisiones globales de 84% en [9] y 89% en [4]. Las precisiones por clase fueron mejores para aquellas de bosques dominados por *Ligustrum lucidum* que para bosques dominados por especies nativas. Según los autores, esto puede deberse a que individuos de *Ligustrum lucidum* se encuentran dentro de bosques dominados por especies nativas, en pequeños parches, y las resoluciones espacial y espectral de los sensores utilizados (Landsat TM/ETM+) no son suficientes para detectarlos.

Algunos autores utilizaron Coh para clasificaciones que distinguen especies arbóreas caducifolias de perennifolias (como coníferas y caducifolias) [10]; o clasificaciones de cobertura y uso de suelo en la que separan la clase bosque de otras clases [11] [12]. Vicente-Guijalba et al. [13] usaron series temporales de Coh para clasificaciones de cobertura de suelo pixel por pixel y basadas en objetos. Alcanzaron precisiones promedio de 80% y consideran la posibilidad de incluir datos de Coeficiente de Retrodispersión (CR) SAR para incrementar la separabilidad de clases sin degradar la resolución de los productos resultantes. Recientemente, investigadores emplearon series temporales de Coh con líneas de base temporales de hasta 12 días en clasificaciones de cobertura/uso de suelo en escenarios diversos: humedales en Canadá [14], el Amazonas [12] y áreas naturales de montaña y de cultivo en Italia, España y Polonia [15]. Éstos encontraron mejoras en la precisión de clasificaciones de ciertos tipos de coberturas al incluir estas series temporales. Estas mejoras fueron encontradas aún cuando las clases a identificar presentan escasa separabilidad como bosques con caducifolias, perennifolias y mixtos; campos agrícolas en seco e irrigados; y suelo desnudo, roca, y áreas escasamente vegetadas[15].

No se encontraron estudios que utilicen Coh para clasificar tipos de bosques que no sea por el criterio de caducidad de las hojas.

Balzter et al. [11], reportan una investigación en la que observaron que en ambientes de cobertura boscosa, no se encontró coherencia entre dos imágenes de banda C, pero si se mantuvo entre dos de banda L. Esto se debió a que por la longitud de onda, los dispersores sensados por la banda C son hojas o pequeñas ramas que se mueven con el viento o crecen; en cambio los sensados por banda L son troncos y grandes ramas que no sufren grandes modificaciones en intervalos de tiempo cortos.

2.2. Vegetación invasora

Las especies *nativas* son aquellas que evolucionaron en una región o llegaron desde otra área sin ayuda del ser humano [3]. Las especies *exóticas*, en su mayoría, deben su presencia directa o indirectamente a actividades humanas. Una especie exótica *invasora* provoca impactos negativos sobre la biodiversidad, el funcionamiento y la estructura del ecosistema invadido. Esto sucede porque tiene determinadas características que posibilitan su rápida dispersión sin la ayuda del hombre en un determinado ambiente que se lo permite [3].

En general, las especies exóticas producen efectos negativos cuando difieren de las especies nativas en productividad, química de los tejidos, morfología de las plantas y fenología [2]. Sin embargo, algunas especies exóticas no tienen efectos negativos sobre el ambiente. Controlarlas sería un gasto excesivo e innecesario de tiempo y dinero [3]. Otras especies, tienen efectos de fácil cuantificación económica. Un ejemplo de ello es el caso de especies arbóreas invasoras en Sudáfrica que disminuyen el aprovisionamiento de agua y cuyo costo de control es apenas el 10 % de este servicio ecosistémico que proveen [3].

Muchos estudios coinciden en que las invasiones por especies vegetales exóticas modifican los ciclos de nutrientes y del agua [1] [2] [3] [4][16]. En una revisión bibliográfica, Ehrenfeld [2] encontró que estas invasiones producen incremento en la biomasa y productividad primaria neta, incremento en el N disponible en el suelo, alteración en las tasas de fijación de nitrógeno, mayor producción de hojarasca y mayor tasa de descomposición. Además, Van der Maarel y Franklin [3] y Hoyos et. al [4] observaron que también se producen cambios en la estructura de los ecosistemas y disminución de la diversidad.

Sin embargo, este comportamiento no se observó en todos los casos estudiados; lo que sugiere que otros factores como la comunidad invadida, factores ambientales y tipo de suelo dirigen finalmente la dirección y magnitud del impacto [2]. Estos factores también influyen en lo observado por Giorgis y Tecco [17]: la cantidad de regiones invadidas por una especie a escala mundial no se corresponde con su agresividad dentro de una región invadida en particular.

Por el nivel de multicausalidad, complejidad en las relaciones y variabilidad de situaciones posibles es que no se puede hablar de especies nativas y exóticas invasoras de manera general, sino que se debe contextualizar en un sitio de estudio determinado.

2.2.1. Leñosas invasoras en el área de estudio

En la región semiárida montañosa del centro de Argentina, en la provincia de Córdoba, se encontró invasión de especies leñosas exóticas hasta ciertos pisos altitudinales [18]. El 91 % de las leñosas invasoras encontradas por Giorgis y Tecco [17] fueron introducidas para uso ornamental, y la zoocoria es la forma de dispersión más frecuente (59% de las especies encontradas).

En esta región las especies leñosas exóticas invasoras modifican el ciclo del agua [1] [4], contribuyen a la pérdida de biodiversidad [4], y modifican los ciclos de los nutrientes. Estos efectos parecen deberse a que las exóticas tienen atributos funcionales que están ausentes en las nativas y les permiten usar más recursos y a una mayor tasa [1]. Para el caso del agua, el consumo es mayor y esto se traduce en mayor transpiración y tasa de crecimiento [1]. Este atributo mejora su capacidad competitiva a través de una más rápida cobertura del suelo en la estación húmeda y tolerancia al estrés hídrico por desprendimiento de hojas en la estación seca (sólo en el caso de caducifolias)[1]. Por otra parte, Karlin et. al [16] demostraron que cuando bosques nativos de esta región son invadidos por especies exóticas invasoras aumentan las probabilidades de ocurrencia de escorrentía.

Se prevee que con el paso del tiempo, cuando aumente la presión de propágulos, las especies arbóreas exóticas invasoras se dispersen a mayor altitud ya que no van a encontrar limitantes de carácter biótico ni abiótico [18]. Los factores que influyen en la presión de propágulos son distancia a asentamientos o calles y vecindad a áreas invadidas [18].

Ligustrum lucidum W.T. Aiton o Siempreverde es la especie arbórea exótica invasora más importante del área de estudio. Es originario de China y Japón y fue introducido en Sierras Chicas, Córdoba para uso ornamental alrededor de 1900 [4] [19] [17]. Desde entonces, mostró una gran capacidad invasora pasando de ocupar pequeñas áreas urbanas en 1983 a cubrir el 20 % de área boscosa de Sierras Chicas en 2006 [9], incluso en áreas protegidas en las que existen medidas de restricción de ingreso [20][21][22]. También se ha encontrado como exótica invasora en otros sitios de América del Sur [21], América del Norte, Islas del Pacífico, Nueva Zelanda, Australia, Sudáfrica, Islas el Atlántico [17].

Entre los caracteres que se asocian a su capacidad invasora se encuentran: tolerancia a la sombra [4][21], dispersión por especies comunes de aves como *Turdus* spp [4][21] que se alimentan de las semillas, y su capacidad de germinar y sobrevivir en una amplia gama de condiciones ecológicas [4][21].

Esta especie mostró tener efectos en la reducción de la biodiversidad. La cobertura herbácea y arbustiva en bosques dominados por siempreverde es considerablemente menor a aquella de bosques dominados por nativas [4] [9].

La distribución de esta especie está relacionada con la dispersión por aves[4][21] que se alimentan de las semillas y las diseminan al pararse y defecar en tocones o postes [21], con la cercanía a zonas urbanas [9], cauces o zonas húmedas y sitios donde ocurrió previamente un disturbio [20]. La invasión de zonas de cauces por especies arbóreas no es muy frecuente en la Provincia de Córdoba. Giorgis y Tecco [17] encontraron sólo cuatro especies exóticas (13 % de las evaluadas) invadiendo bordes de ríos. La relación con la cercanía a áreas urbanas puede ser explicada por dos causas: a) Son fuentes de propágulos, ya que la especie fue introducida a las ciudades con fines ornamentales; b) Disturbios producidos para desarrollos urbanos producen áreas abiertas con suelo desnudo que permiten el establecimiento de esta especie exótica invasora [9].

En el área de estudio (ver sección 3), *Ligustrum lucidum* demuestra ser muy buena competidora de la especie nativa *Sebastiania commersoniana* (Baill.) L.B. Sm. & Downs, debido a su capacidad de tolerar ambientes sombreados. Esta última se encuentra en los márgenes de cursos de agua formando un escalonamiento vertical con *Lithraea molleoides* (Vell.) Engl. (también nativa) que se ubica sobre las laderas que siguen a los márgenes de los cursos de agua [23].

En la Tabla 2.1 se resumen características de estas tres especies. Algunas de estas características permiten pensar el modo de diferenciar bosques nativos de *Sebastiania commersoniana*

y *Lithraea molleoides* invadidos por *Ligustrum lucidum* mediante datos derivados de sensores remotos.

El hecho que las tres especies sean de hojas perennes o semicaducifolias dificulta la diferenciación de bosques invadidos por *Ligustrum lucidum* mediante técnicas de detección de cambios. Estas sí se podrían aplicar si los grupos funcionales fueran diferentes, e.g. especies de hojas caducas vs. perennes. Sin embargo, la diferente época de floración y el cambio de color en las hojas de *Sebastiania commersoniana* podría producir diferencias en las respuestas espectrales a lo largo del tiempo.

Diferencias morfológicas entre las especies pueden generar diferentes niveles de respuesta a la señal SAR. Las especies nativas tienen hojas más pequeñas y cortezas rugosas, mientras que *Ligustrum lucidum* tiene hojas más grandes y corteza lisa. Es de esperarse entonces que al llegar a los bosques de las especies nativas la señal interactúe más con la cubierta y retorne al sensor SAR de forma más atenuada.

Tabla 2.1: Caracteres diferenciales *L. lucidum*, *L. molleoides*, *S. commersoniana*

Especie	<i>L. lucidum</i>	<i>L. molleoides</i>	<i>S. commersoniana</i>	Fuentes
Nombre común	Siempreverde, Ligustro	Molle de beber	Blanquillo, Guindillo, Palo de leche	[23]
Origen	Sur de China y Japón	Nativa	Nativa	[23]
Familia	Oleaceae	Anacardiaceae	Euphorbiaceae	[1]
Altura (m)	3-8	3-8	4-7	[23] [24]
Época de floración	D-F	O-N	O-D	[23]
Época de fructificación	F-My	D-Mz	D-Mz	[23]
Área de la hoja (mm^2)	2768,7	430,3	403,3	[1]
Tamaño de la hoja (mm)	Hojas 55-150 × 30-50	Foliolos 30-80 x 10-20	Hojas 15-60 x 10-25	[25] [24]
Color de la hoja	Verde oscuro brillante en cara adaxial y verde claro en la abaxial	Verde brillante en cara adaxial y verde pálido en la abaxial	Rojizas en otoño e invierno. Verde oscuro lustroso el resto del año	[24]
Mínimo potencial agua de la hoja (MPa)	-2,4	-2,6	-2,4	[1]
Caducidad de las hojas	Perennifolia	Perennifolia	Semicaducifolia	[23] [24]
Corteza	Lisa, con lenticelas	Castaño oscura, rugosa, con láminas que se desprenden	Castaño grisácea, rugosa, con estrías longitudinales paralelas	[24] [23]
Densidad de la madera (g/ml)	0,69	0,58	0,63	[1]
Contenido de agua de la madera (%)	80	57	70	[1]
Estructura vertical de los bosques	Estrato herbáceo y arbustivo muy pobres	Estrato herbáceo pobre	Abundante	[4] [23]
Ubicación	Cerca de áreas urbanas, zonas húmedas o con disturbios	A más de 650msnm En laderas próximas a cursos de agua	En los márgenes de cursos de agua y quebradas cálidas	[4] [23] [20]
Caracteres que favorecen la capacidad de expansión	-Resistencia a la sombra -Dispersión por aves	- Buena capacidad de rebrote de cepa	-Crecimiento rápido -Fruto dehiscente	[4] [23]
Tasa de invasión ($ha \setminus año$)	0,03 ¹	-	-	[20]
Tasa de crecimiento ($cm \setminus año$)	1-3 ²	0.44-0.562 ³	0.58-0.64 ⁴	[26][27] [28]

¹ En Reserva Natural de Vaquerías, Argentina ² En Talares del NE bonaerense, Argentina³ En Guaviyú y Parque Gran Bretaña, Uruguay ⁴ En la planicie del Río Iguazú, Brasil

2.3. Datos ópticos

El espectro electromagnético es la organización de la radiación electromagnética en función de su longitud de onda (o frecuencia) y en bandas donde muestra un comportamiento similar al interactuar con la materia [29].

Una de estas bandas es el dominio óptico del espectro electromagnético, conformado por el grupo de longitudes de onda correspondientes al espectro de emisión del sol [29]. También se incluye a la región del infrarrojo medio, por más que esté también influenciada por la emisión de radiación de los cuerpos observados [29]. Va desde los 0,35 a los 2.6 μm de longitud de onda [30].

Generalmente, un sensor óptico observa la superficie situado en el nadir y mide la proporción de la radiación incidente del sol en la superficie que es reflejada hacia al sensor. Esta medida se denomina reflectancia. Es definida por la Ec. 2.1, se denota con el símbolo ρ y toma valores en el intervalo [0,1].

$$\rho = \frac{E_r}{E_i} \quad (2.1)$$

Donde E_i es la radiación que llega a la superficie y E_r la radiación reflejada hacia el sensor.

Este valor de reflectancia es almacenado en el sensor con valores de contaje digital, por lo que deben ser corregidas *radiométricamente* para obtener valores de reflectancia. Además, contiene también influencia de la interacción de la radiación con la atmósfera, por lo que las imágenes se deben corregir *atmosféricamente* para eliminar esa contribución. Sin embargo, cabe destacar que la necesidad de realizar estas correcciones dependerá del nivel de procesamiento con que el proveedor de imágenes las disponibilice para el usuario.

2.3.1. Vegetación en la región del visible e infrarrojo

En la región visible e infrarroja (0.35 - 2.6 μm) la vegetación intercepta la radiación solar directa y la difusa, interactúa con ella y una parte es reflejada hacia el sensor. Esta interacción es gobernada por factores como pigmentos, contenido hídrico y morfología de la vegetación; y factores asociados a la posición relativa de la planta respecto del sol y del sensor como pendiente, orientación y geometría de plantación [30].

En estudios de laboratorio que miden la reflectividad de la vegetación, puede observarse un patrón general que se describe a continuación y se grafica en la Figura 2.1:

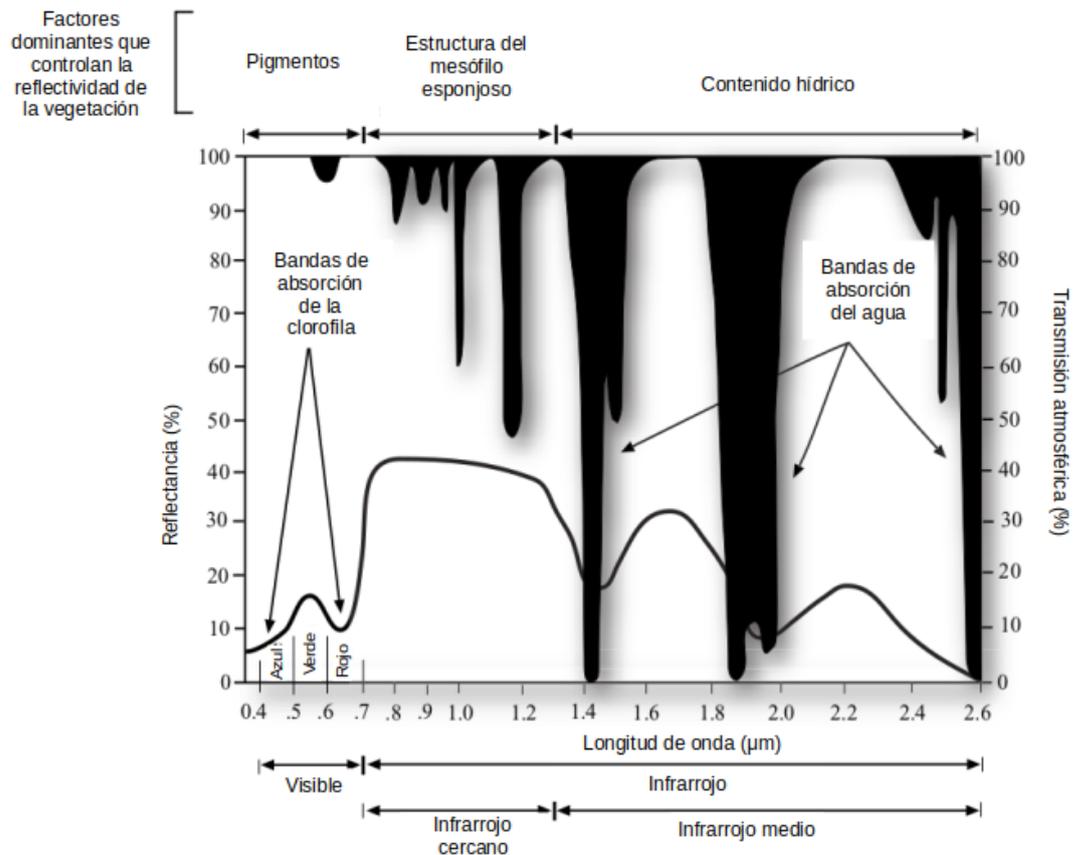


Figura 2.1: Firma espectral de vegetación

La línea negra corresponde a la firma espectral de la vegetación. El área negra corresponde a porciones de absorción de la atmósfera

Fuente: Adaptado de Jensen [30]

En la región **visible**, se observa una reducida reflectividad que se debe a la absorción de pigmentos como clorofila, xantofilos y carotenos. Presenta un máximo relativo en la porción verde ($0,55 \mu m$), en que la absorción de estos pigmentos es menor.

En la región del **infrarrojo cercano** (entre $0,7$ y $1,3 \mu m$) la vegetación presenta una elevada reflectividad, debida a la estructura celular interna de las hojas. El mesófilo esponjoso con sus cavidades de aire internas dispersa la mayor parte de la radiación incidente. Dado que esta estructura varía en las diferentes especies vegetales, la respuesta en esta porción del espectro es variada y por lo tanto útil para discriminar vegetación.

En el **infrarrojo medio** (a partir de $1,4 \mu m$) la reflectividad disminuye drásticamente debido al efecto absorbente de las moléculas de agua, y puede usarse entonces para conocer el vigor de la vegetación. En esta región, se presentan también dos máximos relativos entre los valles de absorción del agua [29].

Si bien esta firma espectral es teórica, y no contempla la acción de otros factores asociados al sensedo remoto, es el fundamento para entender la respuesta espectral de la vegetación obtenida por sensores remotos.

Mediante la combinación de bandas es posible definir índices, entre ellos el **NDVI**. Éste es un Índice Normalizado de Vegetación que aprovecha las diferencias de respuesta de la vegetación en las bandas de infrarrojo cercano ($790nm$) y roja ($670nm$) y puede ser utilizado para diferenciar vegetación. Se define según [31] por la Ec. 2.2.

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (2.2)$$

2.3.2. Imágenes de Sentinel 2 MSI

Sentinel-2 es una misión de la Agencia Espacial Europea. Se trata de una constelación de dos satélites gemelos (A y B) con una alta frecuencia de revisita, de 5 días sobre el Ecuador. Estos satélites llevan a bordo un sensor óptico llamado MSI que mide la reflectancia que llega desde la superficie terrestre entre los 490 nm y los 2190 nm en 13 bandas espectrales de 10 m, 20 m y 60 m de resolución espacial (Tabla 2.2). Las imágenes producidas tienen un ancho de 290 km [32]. Pueden descargarse de manera gratuita de la plataforma *Copernicus Open Access Hub* [33] con dos niveles de procesamiento:

- L1C: Imágenes de reflectancia a tope de atmósfera. Incluye correcciones radiométrica y geométrica.
- L2A: Imágenes de reflectancia en superficie. Son obtenidas con el procesador Sen2Cor que elimina los efectos de la atmósfera, a partir de productos L1C. Están disponibles en *Copernicus Open Access Hub* sólo desde 2018. Para imágenes previas, el mismo usuario puede realizar la corrección atmosférica y topográfica con la misma herramienta Sen2Cor disponible en el software SNAP.

Tabla 2.2: Características de bandas de los sensores MSI a bordo de Sentinel-2. λ : longitud de onda

Nº de banda	λ central (nm)	Ancho de banda (nm)	Resolución espacial (m)
2	490	65	10
3	560	35	10
4	665	30	10
8	842	115	10
5	705	15	20
6	740	15	20
7	783	20	20
8A	865	20	20
11	1610	90	20
12	2190	180	20
1	443	20	60
9	945	20	60
10	1375	30	60

2.4. Datos SAR

Un radar de apertura sintética (SAR) es un sensor activo a bordo de una plataforma que emite un pulso electromagnético hacia la superficie y mide los ecos del mismo que esta refleja [34]. La potencia de estos ecos recibidos es función de los parámetros descritos en la Ec. 2.3.

$$P_r = P_e \frac{G^2 \lambda^2 \sigma^0}{(4\pi)^3 R^4 a} \quad (2.3)$$

Donde:

- P_r : potencia recibida
- P_e : potencia enviada
- G : ganancia de la antena
- λ : longitud de onda
- a : pérdida debido a la absorción del medio de propagación
- R : distancia entre la antena y el blanco

La magnitud física que mide la cantidad de energía que regresa al sensor luego de interactuar con la superficie (blanco) se denomina **CR**. Es una magnitud adimensional que se desprende de la ecuación de radar (Ec. 2.3) y es la suma de las secciones eficaces individuales al radar en relación al área del blanco (Ec. 2.4) [34].

$$\sigma^0 = \frac{\sum \sigma^i}{A} \quad (2.4)$$

El CR se puede expresar de tres maneras:

- Potencia (σ^0): es el flujo promedio por unidad de tiempo que recibe la antena
- Amplitud ($\sqrt{\sigma^0}$): es la raíz cuadrada de la potencia
- Decibeles ($10 \log \sigma^0$): es la potencia expresada en escala logarítmica

El CR depende de las características del sensor, de las del blanco, y de la interacción entre ellos. Entre las características del sensor se encuentran la longitud de onda (λ), polarización, ángulo de incidencia, mirada a izquierda o derecha, modo de observación; y las características del blanco son su geometría y propiedades dieléctricas. De forma general, se puede afirmar que la geometría del blanco determina el mecanismo de retrodispersión dominante, en tanto que sus propiedades dieléctricas la intensidad de la retrodispersión.

Existen 4 mecanismos de retrodispersión dominantes:

- Especular: los rayos incidentes se reflejan con un ángulo similar al de incidencia (ambos tomados con respecto a la perpendicular al plano en ese punto). La señal que regresa al sensor es prácticamente nula. Se observa en cuerpos de agua calmos [34].
- De doble rebote: ocurre en presencia de dos superficies perpendiculares en las que la señal rebota y regresa al sensor en forma casi total. Se observa en áreas urbanas con edificios [34][35], barcos en el mar [34] y bosques inundados en los que la señal rebota en la superficie del agua y en los troncos.
- En volumen: resulta de la interacción de la señal con numerosos objetos presentes en un medio homogéneo. Está presente en bosques [34][35].

- Difusa: ocurre en medios con micro-rugosidad perceptible. La señal es dispersada en muchas direcciones y se observa un incremento de la señal que regresa al sensor. Es el caso de suelos desnudos [35], con restos de cosecha, o escasa vegetación [35].

Se denomina polarización a la orientación del plano de oscilación de la señal propagada [35][34]. La mayoría de los SAR actuales están polarizados linealmente, lo que significa que el plano de propagación se mantiene constante en todo el recorrido de la onda electromagnética [35]. Los SAR pueden controlar la dirección del campo eléctrico emitido, como del recibido. Éstos pueden ser horizontal (H) o vertical (V), generando cuatro posibles combinaciones: HH, VV, HV, VH. Se denominan señales co-polarizadas cuando la dirección de emisión y recepción coinciden (HH o VV) o cross-polarizadas cuando son diferentes (HV y VH) [34].

Conocer la polarización con que es adquirida una imagen SAR es importante ya que señales con diferente polarización actúan de manera diferencial con los objetos presentes en la superficie observada. De manera general, se puede decir que para cada mecanismo de retrodispersión dominante existe una polarización que muestra la mayor potencia de retrodispersión (σ^0) [35]:

- en superficie: $|\sigma_{VV}^0| > |\sigma_{HH}^0| > |\sigma_{HV}^0| \text{ o } |\sigma_{VH}^0|$
- de doble rebote: $|\sigma_{HH}^0| > |\sigma_{VV}^0| > |\sigma_{HV}^0| \text{ o } |\sigma_{VH}^0|$
- de volumen: $|\sigma_{HV}^0| \text{ o } |\sigma_{VH}^0|$

Las propiedades dieléctricas de un blanco se rigen por el contenido de humedad. De modo general, mientras mayor sea el contenido de humedad, mayor será la constante dieléctrica, y mayor el coeficiente de retrodispersión.

2.4.1. Vegetación en imágenes SAR

La mayoría de los sistemas SAR trabaja en una sola banda de frecuencias. Las más utilizadas para aplicaciones de teledetección son las bandas C, X y L con longitudes de onda aproximadas de 3 cm, 6 cm y 24 cm respectivamente [34]. La penetración de la señal en la vegetación aumenta con la longitud de onda, aunque depende también del ángulo de incidencia y de la densidad de la vegetación. Sensores banda X permiten obtener información del tope de la canopia, mientras que aquellos de banda C pueden penetrar en la parte alta del follaje y aquellos de banda L pueden llegar al suelo, si la vegetación no es de bosque muy denso [35]. (Fig. 2.2)



Figura 2.2: Profundidad de penetración diferentes longitudes de onda
Fuente: Africa et. al [35]

2.4.2. Coherencia interferométrica

Dado un par de imágenes SAR, la coherencia es el coeficiente de correlación normalizada entre ambas imágenes estimado en una pequeña ventana [10]. Puede ser utilizada como medida de precisión de la fase interferométrica, o como herramienta para clasificación de imágenes. En una situación ideal, los valores esperados en 2.5 son obtenidos usando un set de observaciones para cada píxel. En la realidad, este procedimiento no es viable, ya que cada píxel es observado solo una vez durante cada adquisición SAR [36]. Es por ello que se obtiene moviendo una ventana a través de toda la imagen SAR. [10]. Puede ser estimada por la Ec. 2.5:

$$\gamma = \frac{E \{y_1 y_2^*\}}{\sqrt{E \{|y_1|^2\} E \{|y_2|^2\}}}, \quad 0 \leq \gamma \leq 1 \quad (2.5)$$

donde y_1 e y_2 son las imágenes y γ es la coherencia interferométrica, entre 0 (baja correlación) y 1 (total correlación).

La discriminación entre áreas con diferente coherencia mejora con el crecimiento del tamaño de la ventana de estimación; pero esto trae como limitación la falta de sensibilidad a píxeles sin coherencia. Por el contrario, cuando hay gran cantidad de píxeles no coherentes, usar ventanas grandes contamina a aquellos píxeles con coherencia. Este problema se puede solucionar usando imágenes corregistradas y empleando una ventana temporal y no espacial [36].

Hanssen [36] muestra que la precisión del estimador de la coherencia de la Ec. 2.5 mejora a medida que aumenta el número de looks ¹ o con valores de coherencia altos (Fig. 2.3).

Esto debe tenerse en cuenta al trabajar con vegetación que presenta valores de coherencia bajos, incluso con líneas de base temporal (días entre adquisiciones) cortas.

¹Looks: Cantidad de subimágenes estadísticamente independientes. Este valor puede ser estimado en áreas homogéneas de la imagen y sirve para cuantificar el nivel de ruido de speckle o de incerteza radiométrica de la imagen

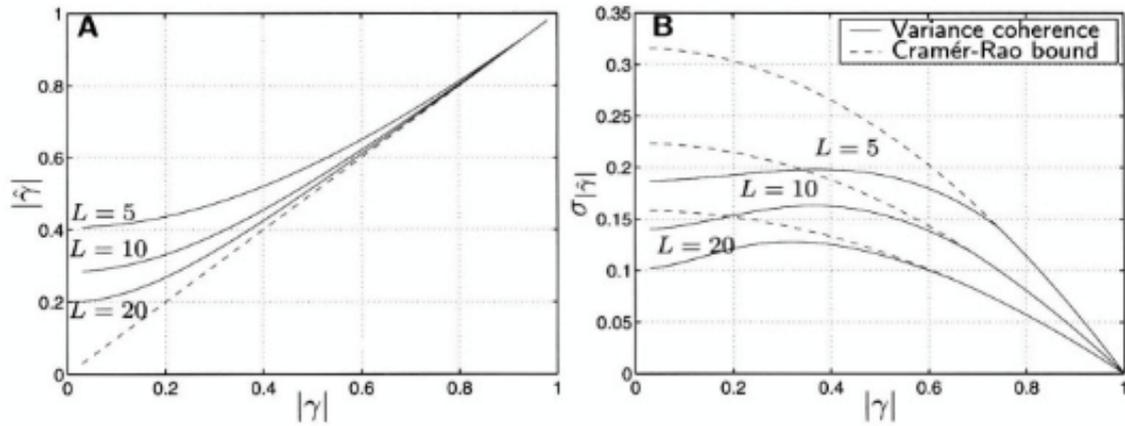


Figura 2.3: Estimador de coherencia $|\hat{\gamma}|$ y varianza del estimador $\sigma_{|\hat{\gamma}|}$ en función del número de looks (L) y del valor real de coherencia $|\gamma|$
Fuente: Hanssen [36]

Por otra parte, la coherencia interferométrica está influenciada por la longitud de onda incidente, como también lo está el coeficiente de retrodispersión. Las mayores longitudes de onda (L o P) son más estables, y la coherencia tiende a mantenerse por periodos de tiempo más largos [11].

2.4.2.1. Fuentes de decorrelación

Se define a *decorrelación* como el ruido causado por fuentes de error que tienen largo de correlación menor que la ventana de estimación de la coherencia [36]. Las fuentes de decorrelación son las causales de la disminución en la coherencia y tienen un efecto multiplicativo (Ec. 2.6). Se detallan a continuación:

$$\gamma_{total} = \gamma_{geom} \times \gamma_{cent\ doppler} \times \gamma_{vol} \times \gamma_{er} \times \gamma_{temp} \times \gamma_{proc} \quad (2.6)$$

- Geométrica γ_{geom} : causada por la diferencia en el ángulo de incidencia entre dos imágenes.
- De centroide Doppler $\gamma_{cent\ doppler}$: causada por la diferencia en los centroides doppler entre dos imágenes.
- De volumen γ_{vol} : causada por la penetración de la onda de radar en los dispersores.
- Térmica o de ruido del sistema γ_{er} : causada por características del sistema, que incluyen factores de ganancia y características de la antena. Sólo es significativa en áreas con muy baja retrodispersión [11]
- Temporal γ_{temp} : causada por cambios físicos en el terreno, que afectan las características dispersoras de la superficie.
- Inducida por el procesamiento γ_{proc} : es causada por los algoritmos elegidos de corrección y de interpolación.

Para el caso de vegetación, las mayores fuentes de decorrelación son las de volumen y temporal. La decorrelación temporal ocurre cuando los dispersores dentro de la celda de resolución

o sus propiedades dieléctricas difieren en función del tiempo entre la primer y la segunda fecha de adquisición, sin tener relación con otras celdas de resolución [36]. En el caso de la vegetación, cambian las características dispersoras por crecimiento, pérdida de follaje o viento; y también cambia su constante dieléctrica por el contenido hídrico o heladas [11].

Generalmente, se observa alta coherencia temporal en áreas sin vegetación frondosa. Para áreas con vegetación se prefieren sensores de mayor longitud de onda, como de banda L, frente a aquellos de banda C o X que tienen menor sensibilidad a pequeños cambios en las características de los dispersores.

La decorrelación de volumen, relacionada con la penetración de las ondas de radar, depende significativamente de las longitudes de onda del radar y del medio de dispersión [36]. Es apreciable por ejemplo en bosques que tienen múltiples capas de blancos retrodispersantes en profundidad [11].

2.4.2.2. Aplicaciones de la coherencia

Es conocido que diferentes tipos de cobertura de suelo presentan valores de coherencia dentro de determinados rangos; y estas diferencias pueden ser utilizadas para mapeos de coberturas [13]. Áreas urbanas o con roca expuesta presentan valores altos (cerca de 1) [37], incluso para líneas de base temporal de varios años [10]. Por el contrario, en cuerpos de agua la superficie está en constante movimiento, por lo que la coherencia es siempre cercana a 0 [10]. Áreas escasamente vegetadas y campos agrícolas tienen valores intermedios de coherencia, aunque en adquisiciones en tándem (con líneas de base temporal de no más de un día) la coherencia es alta. En bosques, si bien el movimiento de las hojas de los árboles puede producir pérdidas en la coherencia, ésta va a ser baja pero no siempre 0. Especies caducifolias presentan mayor coherencia cuando las imágenes utilizadas son de invierno que de verano, ya que en este momento no tienen hojas. Esto puede permitir diferenciarlas de especies perennifolias [10] [11].

Se encontraron estudios sobre distintos tipos de vegetación, mediante el uso de coherencia interferométrica. Wegmuller et al., 2015 [37] evaluaron la capacidad de la coherencia interferométrica para la clasificación de cultivos, y encontraron que en cultivos abiertos la coherencia es baja con imágenes separadas por 12 días (excepto para cultivos ya cosechados, con suelo desnudo) y decrece drásticamente en aquellas separadas por 24 y 48 días.

Según Ferreti et. al [10] la Coh está linealmente relacionada con la altura del cultivo, por lo que permite hacer estimaciones de biomasa. Técnicas multitemporales pueden posibilitar la identificación de patrones temporales relacionados con la fenología de cultivos y crecimiento de vegetación en general. Cambios en el CR (y reducción de la Coh) son producidos por irrigación o labores mecánicas [11]; en cambio en áreas áridas sin vegetación la coherencia es siempre alta.[37]

En Baltzer [11] también se reportan aplicaciones de estimación de biomasa y altura de árboles en bosques. La Coh parece decrecer con el incremento de la biomasa, aunque la precisión depende considerablemente de la estructura de la vegetación y de las condiciones de campo.

La combinación de CR y Coh tiene aplicaciones en la clasificación de bosques. El CR aporta información de la estructura y contenido de humedad del blanco, en tanto que la Coh sobre el comportamiento en el tiempo [10].

Otra aplicación es la detección de cambios [37]; por ejemplo la segmentación de áreas forestadas y no forestadas [11] que puede servir para la detección de forestaciones dañadas por

incendios [10] o fuertes vientos, o para inventarios forestales.

2.4.2.3. Pasos para obtener la estimación de coherencia

Se describen a continuación los pasos a seguir para obtener la estimación de la coherencia interferométrica. Los pasos señalados con (*) son exclusivos para imágenes Sentinel-1 IW SLC.

1. Selección de imágenes

El par de imágenes deben ser tomadas por el mismo sensor, con el mismo modo de adquisición, el mismo tipo de pasada (ascendente o descendente ²) y deben ser de la misma trayectoria orbital (orbital track). La selección de imágenes para la estimación de coherencia depende de diversos factores. En cuanto al objetivo de estudio, si es el uso de InSAR para el estudio de deformaciones deberá equilibrar la elección entre la B_{\perp} , $B_{\perp,crit}$, $B_{temporal}$, en tanto que si el objetivo es la clasificación de unidades de cobertura a partir de mapas de coherencia interferométrica se priorizará la menor $B_{temporal}$.³

En la actualidad, hay productos de diversos sensores con geometría de adquisición apropiados para estudios de interferometría:

- ALOS-PALSAR-1[35]
- TerraSAR-X[35]
- Tandem-X[35]
- Radarsat-2[35]
- COSMO-SkyMed[35]
- ALOS-PALSAR-2[35]
- Sentinel-1[35]
- SAOCOM

La elección de uno u otro surgirá de relacionar el objetivo del análisis con la disponibilidad de imágenes o la posibilidad de programar adquisiciones, la resolución temporal del sensor, el modo de adquisición del sensor, el tamaño del área de estudio, la longitud de onda del sensor, la relación señal/ruido, las características del blanco, la disponibilidad de financiamiento para la compra de imágenes o de convenios de cooperación para obtenerlas sin costo, el tiempo y las aplicaciones disponibles para el procesamiento.

En áreas de montaña es necesario considerar los efectos de la deformación geométrica [10]. Si hay deformación geométrica por acortamiento⁴ la coherencia es muy baja en cuanto la B_{\perp} sea mayor a unos pocos metros. Por su parte, áreas en pendientes opuestas tienen la mejor coherencia si no está en la sombra. La combinación de mapas de coherencia con órbitas ascendentes y descendentes puede mejorar la interpretación [36].

²Durante el movimiento por su órbita, un sensor puede mirar a la superficie terrestre de dos modos: ascendente si recorre a la tierra de Sur a Norte y descendente si lo hace de Norte a Sur

³ B_{\perp} o línea de base perpendicular es la distancia entre dos antenas SAR en el momento de las adquisiciones en cuestión, mientras que $B_{temporal}$ o línea de base temporal es el tiempo entre dos adquisiciones [36]. $B_{\perp,crit}$ es la B_{\perp} máxima a la que el sistema es sensible a la decorrelación geométrica.

⁴En inglés, foreshortening. Tiene lugar cuando las pendientes están orientadas hacia el sensor y la señal SAR alcanza antes la base que la cima. Las laderas aparecen *comprimidas*

Por otra parte, factores meteorológicos como el viento y la lluvia hacen disminuir la coherencia, por lo que [10] y [36] sugieren considerar la información meteorológica al momento de la selección de imágenes.

2. Corrección

Previamente a la estimación del mapa de coherencia las imágenes deben ser corregidas en un mismo archivo (un apilado de bandas o *stack*). La primera imagen se llama *máster* y va a ser tomada como referencia para mover la segunda imagen o *esclava*. El objetivo es asegurar que cada blanco en la superficie aporte al mismo píxel en la esclava y la *máster* con una precisión sub píxel. [36] [10] [38] [35]. La precisión óptima es de 0.2 píxel [11]. Si bien la atmósfera es transparente para las longitudes de onda de los sensores SAR, se recomienda consultar datos meteorológicos de la fecha de adquisición de la imagen *máster*, dado que la presencia de nubes en la escena puede disminuir la precisión de la corrección [10] y [36].

Este procedimiento consiste en pequeñas rotaciones, estiramientos en rango y azimut, y efectos secundarios que éstos traen. Los coeficientes que definen las magnitudes y dirección de estos movimientos son estimados para cada pequeño parche en la que la imagen se divide, utilizando información de la geometría de adquisición y del DEM [10] [37]. Se asume que la imagen esclava es la única que es modificada, por lo que el interferograma y el mapa de coherencia que se realicen luego van a tener la misma geometría que la imagen *máster* [10].

La secuencia de pasos involucrados en este procedimiento es:

a) Recorte o división (*Split*) (*)

Es el primer paso en la cadena de procesamiento InSAR con imágenes Sentinel-1 IW SLC. Este procedimiento consiste en separar el archivo original en *subswaths*⁵, con opción de elegir también determinados *burst*⁶ y polarización.

b) Aplicación de archivo de órbita precisa (*Apply orbit file*)

Debido a que los vectores de estado disponibles en los metadatos de los productos SAR son poco precisos, se recomienda mejorar su precisión con archivos de órbita precisa que contienen información de órbita y velocidad del sensor. Son generados y puestos a disposición de días a semanas después de la adquisición.

c) Geocodificación (*Back geocoding*)

Esta herramienta corrige los mismos números de *swath* de las dos imágenes (*máster* y esclava) mediante la información de órbita de las dos imágenes y un DEM.

d) Mejora de diversidad espectral (*Enhanced Spectral Diversity*) (*)

Es el paso que le sigue al *back geocoding* cuando las imágenes son Sentinel-1 IW SLC en SNAP. El objetivo es mejorar la precisión de la corrección. En primera instancia, estima el desplazamiento en rango⁷ para cada *subswath* de la imagen esclava. Esta estimación es hecha para cada *burst* en una pequeña porción en el centro. La estimación final para toda la imagen es obtenida como el promedio de todas las estimaciones de los *burst*.

⁵Subswaths: Sub-escenas en las que vienen divididas las imágenes Sentinel-1 IW

⁶Burst: cada sub-imagen en las que se dividen los sub-swaths de las imágenes Sentinel-1 IW

⁷Desplazamiento en rango: En dirección perpendicular a la línea de vuelo de la plataforma que lleva al sensor

La estimación del desplazamiento en azimut⁸ para cada subswath es estimada mediante el método de diversidad espectral mejorada (ESD es su sigla en inglés). Este método explota los datos en el área superpuesta de burst adyacentes y se realizan estimaciones mediante ventanas en estas áreas de superposición. Luego se promedian estas estimaciones para obtener el desplazamiento de toda la imagen. Tanto las estimaciones de rango como de azimut son guardadas en los metadatos del producto.

Por último, las estimaciones de desplazamiento en rango y en azimut son aplicadas a la imagen esclava con el método de rampa de fase en dominio de frecuencia.

3. Creación de la matriz de coherencia

La manera en que se estima la coherencia interferométrica se describe en 2.4.2. SNAP [39] dispone de una herramienta para la estimación, que no es exclusiva para aplicaciones InSAR. Puede ser utilizada para estimar la correlación entre cualquier par de imágenes complejas corregidas. Como un paso posterior, puede aplicarse multilooking⁹ con el objetivo de reducir el ruido, a expensas de la pérdida de resolución espacial.

4. Unión de *bursts* y *subswaths* (*TOPS deburst* y *Merge deburst*) (*)

El objetivo de estos pasos es unir los burst y subswath en los que se encuentran divididos las imágenes IW SLC de las plataformas Sentinel 1 (ver 2.4.3). Pueden aplicarse a la imagen cruda o ya procesada. El resultado, es una sola imagen que contiene todos los burst de los 3 subswath de esa adquisición.

5. Corrección de terreno (*Range Doppler terrain correction*)

El objetivo es compensar las distorsiones geométricas que se generan debido a la visión lateral del sensor. Implementa el método de ortorectificación range doppler en el que utiliza información de los metadatos de las imágenes y un DEM para obtener información precisa de geolocalización. Con la herramienta de SNAP se pueden utilizar los DEM SRTM 3sec o 1sec que se descargan automáticamente o bien utilizar un DEM externo desde un archivo. Este tiene que estar en formato GeoTiff, con coordenadas geográficas, referido al sistema de referencia WGS84 y con la altura en metros.

2.4.3. Imágenes Sentinel 1 IW SLC

A continuación, se resumen algunos detalles relevantes de las imágenes de los sensores a bordo de los satélites Sentinel 1, adquiridas con el modo Interferometric Wide swath. Más información puede encontrarse en el manual de usuario de estos satélites [40]. Los satélites Sentinel 1 A y B pueden operar en cuatro modos de adquisición:

- Stripmap (SM)
- Interferometric Wide swath (IW)
- Extra-Wide swath (EW)
- Wave (WV)

⁸Desplazamiento en azimut: En la dirección de vuelo de la plataforma que lleva al sensor

⁹Multilooking: Promedio de sub-imágenes, estadísticamente independientes, correspondientes a la misma escena. Mejora la incerteza radiométrica a expensas de pérdida de resolución espacial.

El modo de adquisición adecuado para trabajar con coherencia interferométrica es el Interferometric Wide swath. Este modo releva la superficie usando Terrain Observation with Progressive Scans SAR (TOPSAR), que reduce ampliamente el problema de scalloping que se produce con los Scansar convencionales.

Con este modo se adquiere información con un ancho de barrido de 250 km y resolución espacial de 5 m a 20 m, en tres sub-swath con 9 bursts dentro de cada uno de ellos, para cada polarización. Cada burst es procesado como una imagen SLC por separado, y se incluyen luego en la imagen de cada swath en el orden en que fueron siendo adquiridos, con líneas negras de demarcación entre los burst. Existen pequeñas áreas de solapamiento entre los burst adyacentes con el fin de asegurar la continua cobertura del área. Las imágenes para todos los burst de todos los swath son remuestreados a un tamaño de píxel común en rango y acimut mientras que se preserva la información de fase.

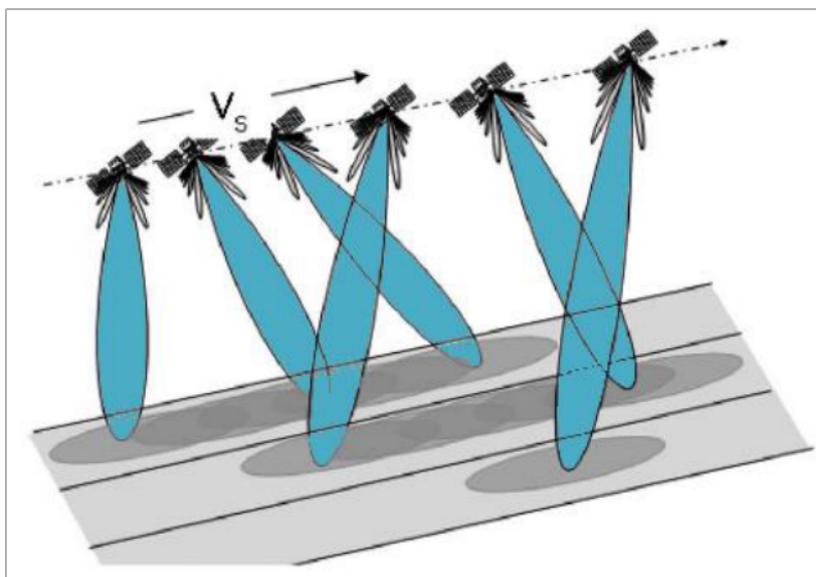


Figura 2.4: Modo de adquisición TOPSAR Sentinel 1
Fuente: Manual de usuario Sentinel-1 [40]

Los niveles de procesamiento disponibles para el IW de S1 son L0 RAW, L1 SLC, L1 GRD high y medium resolution y L2 OCN. En la presente tesis se utilizan L1 SLC. Estas imágenes consisten en datos SAR focalizados, georreferenciados utilizando información de órbita y altitud del satélite y en geometría de rango oblicuo.

2.5. Separabilidad de clases

2.5.1. Análisis marginal

2.5.1.1. Gráficos de caja y bigotes o Boxplots

Estos gráficos son utilizados para mejorar la interpretación sobre los datos y ayudan a hacer comparaciones entre muestras. Un boxplot está compuesto por:

- Caja: el largo de la caja se define por los cuartiles 1 ($Q1$) y 3 ($Q3$). La distancia que hay entre estos dos valores es el rango intercuartílico (IQR). La línea dentro de la

caja es la mediana o el cuartil 2 (Q_2): es el valor central de los datos y divide a la mitad la distribución. El ancho de la caja suele ser arbitrario, pero se puede escalar en proporción a \sqrt{n} para representar el tamaño de la muestra.

- Bigotes: los límites de los bigotes representan los valores extremos normales, es decir, los valores extremos dentro del rango determinado por 1,5 veces el rango intercuartílico [41].
- Valores raros o outliers: son definidos como aquellos que se extienden más allá de 1.5 veces el rango intercuartílico, y se grafican como puntos.
- Media: se representa con un punto dentro de la caja.

Estos elementos se grafican en la Fig. 2.5.

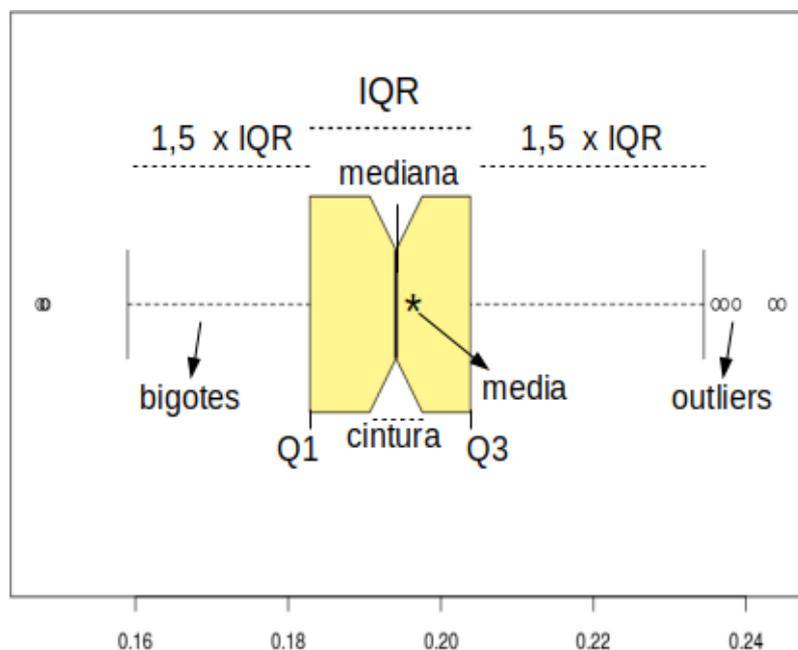


Figura 2.5: Elementos de un boxplot: Q_1 , Q_3 , IQR, mediana, bigotes, outliers
Fuente: adaptado de Krzywinski y Altman [41]

Para realizar estos gráficos es necesario contar con una cantidad mínima de 5 observaciones (n). Al ser graficados de modo horizontal facilitan interpretaciones sobre la distribución de los datos.

Para mejorar la visualización de las diferencias entre medianas se pueden graficar las cinturas de las cajas que muestran el intervalo de confianza del 95 % de la mediana con la fórmula $mediana \pm 1,58 IQR / \sqrt{n}$ [41]. Esta aproximación está basada en la distribución normal pero es precisa para otras distribuciones si las muestras son grandes [41] [42]. En general, cuando las cinturas no se tocan se puede decir que las diferencias entre las medianas son significativas, pero el solapamiento no es regla de ausencia de significancia [41]. Esta premisa es una guía útil para comparar medianas aún cuando no se cumplen estrictamente los supuestos de las pruebas de hipótesis [42].

Al graficar boxplots con programas estadísticos la posición exacta de las cajas dependerá del programa ya que, en primer lugar, no existe un método universalmente acordado para calcular los valores del cuartil, que puede basarse en un promedio simple o una interpolación

lineal. En segundo lugar, algunos programas, como R, usan bisagras en lugar de cuartiles para calcular los límites de la caja. Las bisagras inferior y superior son la mediana de la mitad inferior y superior de los datos, respectivamente, incluida la mediana si es parte de los datos. Las cajas basadas en bisagras serán ligeramente diferentes en algunas circunstancias a las basadas en cuartiles. Es por ello que Krzywinski y Altman [41] recomiendan que aspectos como el modo de determinar el ancho, el tamaño de los bigotes, las cinturas y los outliers deben ser descritas en las leyendas de los gráficos.

2.5.1.2. Pruebas de diferencias de medias

El ANOVA (en inglés analysis of variance) es un test de diferencias de medias de más de dos grupos o poblaciones. Se toman muestras aleatorias independientes de a poblaciones, normales, con medias μ_1, μ_2, μ_a y varianza común σ^2 [43]. Las hipótesis son las siguientes:

- $H_0 : \mu_1 = \dots = \mu_a$
- H_1 : Al menos una de las a medias poblacionales es distinta

donde a representa la cantidad de medias poblacionales a comparar [44].

Para contrastar estas hipótesis el ANOVA utiliza un modelo lineal que se detalla a continuación (Ec. 2.7)

$$Y_{ij} = \mu + \tau_i + \varepsilon_{ij} \text{ con } i = 1, \dots, a \text{ y } j = 1, \dots, n \quad (2.7)$$

Donde:

a denota la cantidad de poblaciones en evaluación

n indica la cantidad de unidades experimentales que se evaluarán de cada población

Y_{ij} es la j -ésima observación de la i -ésima población

μ es la media general

τ_i es el efecto de la i -ésima población

ε_{ij} es una variable aleatoria normal independientemente distribuida con esperanza 0 y varianza $\sigma^2 \forall i, j$

Este modelo explica que cada observación está compuesta por: una cantidad fija desconocida μ , otra también desconocida τ_i que explica como cambia cada observación Y_{ij} debido al hecho de pertenecer a la población i , y un último componente aleatorio ε_{ij} sobre el que el investigador no tiene control.

Estos componentes, si bien son desconocidos, son estimados y se utilizan para construir dos estimadores de varianzas que luego se comparan en el ANOVA mediante el estadístico F igual al cociente de dos varianzas. Estas varianzas son la varianza *dentro* de tratamientos o poblaciones que es estimada por el CMD y la varianza *entre* los mismos, estimada por el CME.

Sean σ_E^2 y σ_D^2 las varianzas estimadas por el CME y el CMD, respectivamente, si la hipótesis nula de igualdad de medias poblacionales es verdadera ocurre que $\sigma_E^2 = \sigma_D^2$. Por el contrario, si la hipótesis nula es falsa $\sigma_E^2 > \sigma_D^2$. Entonces, las hipótesis nula (H_0) y alternativa (H_1) se pueden reescribir como:

- $H_0 : \sigma_E^2 = \sigma_D^2$

$$\blacksquare H_1 : \sigma_E^2 > \sigma_D^2$$

Para probar esta hipótesis nula (H_0) se utiliza el estadístico F con una distribución Fisher con $a - 1$ grados de libertad en el numerador y $N - a$ grados de libertad en el denominador, siendo a el número de poblaciones y N el de observaciones. El F_{obs} se construye utilizando los estimadores de σ_E^2 y σ_D^2 , según Ec. 2.8:

$$F_{obs} = \frac{CME}{CMD} \quad (2.8)$$

Luego, se comparan $F_{a-1, N-a}$ y F_{obs} para un nivel de significación α : si F_{obs} es mayor que el cuantil $1 - \alpha$ de la distribución $F(a-1), (N-a)$ se rechaza H_0 , implicando que H_1 es verdadera [44][43]. Además, también puede utilizarse el $p - valor$ que se compara con el nivel de significación fijado (α) y si el $p - valor$ es menor que α , se concluye rechazando la hipótesis nula [43]. Esto quiere decir, que al menos un par de medias es estadísticamente diferente.

Una vez rechazada la hipótesis nula, se procede a realizar una prueba “*a posteriori*” con el objetivo de determinar cuáles son los pares de poblaciones que tienen medias diferentes. Una de estas pruebas es el *Test de Tukey* que examina con un mismo estadístico todas las diferencias de medias muestrales en estudio. El estadístico que emplea es el DMS_t (diferencia mínima significativa). Si el valor absoluto de la diferencia entre un par de medias supera al DMS_t , se dice que esta diferencia es estadísticamente significativa [44].

Los software estadísticos como *R* además calculan el intervalo de confianza de la diferencia entre un par de medias y el $p - valor$. Si las medias que se están comparando son estadísticamente distintas, el intervalo de confianza de la diferencia entre ellas no incluirá el cero y el $p - valor$ será menor al nivel de significancia α .

Esta prueba es muy utilizada en muchos campos de investigación, pero según Balzarini et al. [44] en ocasiones en que los tamaños muestrales de las poblaciones son muy diferentes, esta prueba de Tukey puede dejar de ser confiable.

Volviendo al inicio, el ANOVA suponía que las muestras son aleatorias, independientes, con distribución normal y varianza común σ^2 [43]. Para que el modelo y las conclusiones que a partir de él se pueden emitir sean válidos se debe comprobar que las muestras cumplen con estos supuestos:

- Independencia: se asegura mediante un buen proceso de aleatorización en el muestreo.
- Normalidad: unas de las pruebas que se pueden utilizar son las de Kolmogorov-Smirnov o Shapiro-Wilks sobre los residuos estandarizados. La hipótesis nula (H_0) plantea que la distribución es normal, mientras que la hipótesis alternativa (H_1) que no lo es [43]. Si el $p - valor$ de esta prueba es mayor al nivel de significancia, se concluye que las muestras tienen distribución normal.
- Homogeneidad u homocedasticidad de varianzas: Supone la igual dispersión de las varianzas. Se emplea la prueba de Levene que tiene como hipótesis nula (H_0): $\sigma_1^2 = \sigma_2^2 = \sigma_a^2$, contra la hipótesis alternativa (H_1) que la hipótesis nula es falsa [43]. Si el $p - valor$ de esta prueba es mayor al nivel de significancia, se concluye que las varianzas de las muestras son iguales.

Cuando el supuesto de normalidad no se cumple debe optarse por usar tanto pruebas de diferencias de medias como de homogeneidad de varianzas no paramétricos, que no se basan en este supuesto.

La prueba de Kruskal-Wallis [45], a diferencia del ANOVA en el que se comparan medias, contrasta si las diferentes muestras están equidistribuidas y por lo tanto si pertenecen a una misma distribución (población). Puede considerarse, bajo ciertas simplificaciones, que este test compara las medianas. Las hipótesis que se contrastan son:

- H_0 : las k muestras provienen de la misma población (distribución)
- H_1 : Al menos una muestra proviene de una población con una distribución distinta.

Esta prueba emplea el estadístico H que se obtiene con la Ec. 2.9 para k grupos cada uno con n observaciones. Se ordenan todas las observaciones de menor a mayor, se le asigna a cada una de ellas su rango y se suman los rangos para cada uno de los grupos (R_i). Si se cumple la hipótesis nula, se espera que todos los grupos tengan un valor de rango similar.

$$H = \frac{12}{N(N+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(N+1) \quad (2.9)$$

El estadístico H_{obs} se compara:

- Si el tamaño de grupos k es igual a 3 y el número de observaciones en cada uno no es mayor que 5: con valores teóricos de H tabulados.
- En el resto de casos: se asume que el estadístico H sigue una distribución χ^2 con $k-1$ grados de libertad (siendo k el número de grupos a comparar).

Dos supuestos deben cumplirse para que los resultados de este test sean válidos:

- Dado que la hipótesis nula asume que todos los grupos pertenecen a una misma población y que por lo tanto tienen las mismas medianas, es requisito necesario que todos los grupos tengan la misma varianza.
- Misma distribución para todos los grupos.

El primer supuesto (de homogeneidad de varianzas) puede comprobarse con una prueba no paramétrica como la de Fligner-Killeen [46]. Esta prueba compara las varianzas basándose en la mediana. La hipótesis H_0 es que las varianzas son iguales, mientras H_1 que no lo son. El estadístico empleado tiene una distribución aproximada χ^2 con $k-1$ grados de libertad.

2.5.2. Análisis de estructura temporal

Cada píxel de una serie temporal de imágenes puede ser pensado como un vector donde cada elemento del mismo corresponde al valor de ese píxel en cada fecha de la serie temporal. Por lo tanto, medidas de distancia entre vectores pueden utilizarse para comparar series temporales.

Las medidas más utilizadas son aquellas que se basan en la cercanía entre los valores que toman los vectores en una misma posición. Ejemplos de estas medidas son la distancia Euclídea [47], el *Dynamic Time Warping* [47], la distancia de Frèchet [47], o la distancia de Bray Curtis [48].

La distancia Euclidea δ entre dos vectores (U y V) se define mediante la Ec. 2.10[47]:

$$\delta(U, V) = \left(\sum_{i=1}^p (u_i - v_i)^2 \right)^{1/2} \quad (2.10)$$

La distancia Bray-Curtis entre dos vectores (U y V) (Ec. 2.11) toma valores entre [0,1], si todas las coordenadas son positivas. Valores cercanos a 0 indican que los vectores son iguales, mientras que cercanos a 1 que son completamente distintos.

$$DBC(U, V) = \sum |u_i - v_i| / \sum |u_i + v_i| \quad (2.11)$$

La desventaja de este tipo de medidas es que no tienen en cuenta las variaciones en la estructura temporal de las series de tiempo, por lo que su capacidad para determinar su similitud es reducida.

Para superar esta limitación, Chouakria y Nagabhushan [47] propusieron un nuevo índice de disimilitud “D” (Ec. 2.12) que evalúa tanto la cercanía entre valores de las series temporales, como la similitud de las variaciones en la estructura temporal de las mismas. Para ello, definen a esta distancia como el producto entre la correlación temporal afectada por una función de tuning adaptiva exponencial (Ec. 2.13), y una medida de distancia vectorial convencional como la distancia Euclidea. El primer factor evalúa la similitud en las variaciones de la estructura temporal entre las series, mientras que el segundo (en la ecuación, δ) evalúa las distancias entre los valores que toman las series en una misma posición o momento de tiempo. El coeficiente k determina cuál será la contribución de cada uno de los dos factores en la distancia D resultante.

$$D(U, V) = f(cort(U, V)) \cdot \delta(U, V) \quad (2.12)$$

La función de tuning adaptiva exponencial se define por la Ec. 2.13, mientras que el coeficiente de correlación temporal ($cort$) por la Ec. 2.14, y puede tomar valores en el intervalo [-1,1].:

$$f(x) = \frac{2}{1 + \exp(kx)}, \quad k \geq 0 \quad (2.13)$$

$$cort(U, V) = \frac{\sum_{i=1}^{p-1} (u_{(i+1)} - u_i)(v_{(i+1)} - v_i)}{\sqrt{\sum_{i=1}^{p-1} (u_{(i+1)} - u_i)^2} \sqrt{\sum_{i=1}^{p-1} (v_{(i+1)} - v_i)^2}} \quad (2.14)$$

2.6. Clasificaciones

Clasificar una imagen o un conjunto de ellas consiste en agrupar píxeles por la semejanza de características que presenten en la/s imagen/es a clasificar. El resultado es una nueva imagen, en la que cada uno de los píxeles adquiere como valor a un número que es el identificador de la clase a la que ha sido asignado [29]. El conocimiento del área de estudio es fundamental para relacionar las clases obtenidas digitalmente con las clases de interés.

Los pasos involucrados en una clasificación pueden resumirse en: entrenamiento, asignación y validación. Durante el entrenamiento, se reconocen patrones tipo (o clases). En la fase de

asignación se identifica a cada píxel con uno de esos patrones previamente definidos. Por último, en la fase de validación, se corrobora que las asignaciones realizadas hayan sido correctas.

Los métodos de clasificación se dividen en dos grandes grupos en función de cómo es realizada la fase de entrenamiento: supervisados y no supervisados. En los métodos supervisados, el usuario conoce previamente el terreno y selecciona muestras o áreas de interés representativas de cada clase. Para ello, éstas muestras deben ser homogéneas y lo suficientemente grandes. El algoritmo de clasificación agrupa a los píxeles en esas clases previamente definidas. En el caso de las clasificaciones no supervisadas, el algoritmo de clasificación es el que busca de manera automática grupos de píxeles con valores homogéneos. Luego es tarea del usuario encontrar las correspondencias entre las clases encontradas por el algoritmo y sus clases de interés en el terreno.

Los algoritmos utilizados durante la fase de asignación de las clasificaciones se describen en la sección 2.6.2, mientras que los procedimientos involucrados en la validación, en la sección 2.6.3.

2.6.1. Clasificaciones con Series Temporales

Una serie temporal es un conjunto de observaciones de una variable, ordenadas cronológicamente. En el caso de las imágenes satelitales, las variables pueden ser físicas (como la reflectancia o el coeficiente de retrodispersión), o pueden ser índices derivados de ellos (como NDVI, LAI). Cada píxel contiene entonces información de una secuencia de observaciones ordenada temporalmente. Idealmente, las observaciones están equiespaciadas en el tiempo; aunque esto a menudo no se cumple en el caso de imágenes de sensores ópticos, en el que algunas observaciones deben ser descartadas por efectos de nubes.

Imágenes satelitales o sus productos derivados de una sola fecha a veces tienen posibilidad limitada de discriminación entre clases dada la similitud en el comportamiento de las mismas. Las series temporales aportan información sobre la dinámica de una variable [29], y pueden mejorar la calidad de las clasificaciones, con respecto a aquellas basadas en imágenes de una sola fecha. Tales mejoras se observaron en clasificaciones de cobertura de suelo [49], de cultivos [50] y de bosques [51].

En el caso de clases de vegetación, la precisión de las clasificaciones depende también del momento del ciclo de crecimiento que abarque la serie temporal [50] [51]. El análisis de series intraanuales puede brindar información sobre las diferencias fenológicas entre especies vegetales mientras que series interanuales sobre la dinámica de la cobertura terrestre [49].

El uso de series temporales de imágenes ópticas y SAR en conjunto también mejora la precisión de las clasificaciones [50].

2.6.2. Algoritmos de clasificación

Se detallan a continuación los algoritmos utilizados durante la fase de asignación en las clasificaciones de la presente tesis.

2.6.2.1. Árbol de decisión

Es un algoritmo de tipo no supervisado. Está compuesto por capas de nodos que asemejan la estructura de un árbol. Según la posición son llamados nodos de *raíz*, *interiores* o *terminales*. Los nodos de *raíz* e *interiores* se agrupan en *no terminales*, y en cada uno una decisión debe ser tomada para avanzar hacia un nodo siguiente. Los nodos *terminales* representan el final de la clasificación.

Pueden ser considerados dos tipos de diseño de árboles de decisión: manual o automático. El primer tipo, está basado en el conocimiento del usuario de las propiedades de las clases y la relación entre ellas. Consume tiempo y puede no proveer resultados satisfactorios [52]. En el segundo tipo, el ordenador crea el árbol de decisión, basado en los datos de entrada. Se puede optar por uno u otro diseño en base a medidas de calidad de un clasificador como los resultados obtenidos, o su eficiencia computacional [52].

La mayor ventaja de los clasificadores de árboles de decisión es que su estructura puede ser representada gráficamente, y es fácil de interpretar la relación entre entradas y salidas [52] [53]. Además, tienen bajo costo computacional [53].

2.6.2.2. Random Forest

Es un clasificador de tipo supervisado. Consiste en una combinación de clasificadores de árbol. Cada uno de estos es generado usando un vector aleatorio muestreado independientemente del conjunto de datos de entrenamiento. Cada muestra (vector) es entregada a estos clasificadores de árbol quienes dan un voto unitario para la clase en la que asignar al vector de entrada. Finalmente, cada muestra (vector) es asignada a la clase para la que haya recibido más votos de los clasificadores [52].

Actualmente, es un algoritmo ampliamente utilizado para la clasificación de imágenes satelitales debido a su capacidad de trabajar con datos no distribuidos normalmente y de gran dimensión [54].

2.6.2.3. Support Vector Machine

Es un método supervisado, no paramétrico. Este crea un hiperplano óptimo de separación de clases basado en las muestras de entrenamiento [52] [53], pero no necesariamente todas ellas [52].

El caso más simple consiste en dos clases en un espacio bidimensional, linealmente separables y este "hiperplano" es en realidad un línea recta. En el caso de datos derivados de teledetección, raramente se trata de un espacio bidimensional, la separabilidad de las clases es baja y no son linealmente separables, y no hay sólo dos clases [53]. Sin embargo, en estos casos pueden aplicarse enfoques basados en constantes de regularización o funciones de transformación no lineal llamadas kernels para reducir la complejidad de la clasificación.

La ventaja de esta técnica es que genera clasificaciones precisas, y necesita menor cantidad de muestras de entrenamiento que otras técnicas de aprendizaje automático con clasificaciones de precisión similar como redes neuronales [52].

2.6.2.4. Análisis discriminante

El análisis discriminante (AD) describe algebraicamente la relación entre dos o más grupos de manera tal que las diferencias entre ellas se maximicen [55]. Puede ser usado con el objetivo de clasificar nuevas muestras sobre las cuales de desconoce el grupo al que pertenecen[55][56]; para encontrar el subconjunto de variables que mejor explica la variabilidad entre grupos[55][56]; o como una técnica de reducción de dimensión relacionada al Análisis de Componentes Principales [55].

Se parte de una variable dependiente categórica con k grupos en el que el agrupamiento es conocido a priori, y de n variables independientes métricas. En el análisis discriminante lineal se construyen $k - 1$ funciones discriminantes lineales (FDL) no correlacionadas. Estas son una combinación lineal de las variables originales, en las que la suma de cuadrados de las diferencias entre grupos, para cada combinación, sobre la varianza dentro de los grupos es máxima [55]. Cada función discriminante tendrá mayor poder explicativo que la siguiente. Geométricamente, pueden ser pensadas como el eje que atraviesa la nube de puntos en el hiperespacio de manera tal que la proyección de los puntos sobre ese eje es la que muestra mayor diferencia entre grupos [57].

Como supuesto se asume que las matrices de varianza-covarianza de las variables, son homogéneas o iguales estadísticamente entre las poblaciones de análisis. En el caso que estas matrices no sean iguales, se puede desarrollar una función discriminante cuadrática. Sin embargo, numerosos trabajos estadísticos muestran que aún cuando no se cumple este supuesto, las tasas de error de clasificación usando una función discriminante lineal pueden ser bajas [57].

A menudo se suelen realizar análisis de la varianza para seleccionar las variables que tengan mejor capacidad de discriminar grupos, antes del análisis discriminante. Pero puede ocurrir que este enfoque sea riesgoso, y se eliminen variables que en el enfoque individual discriminan de manera deficiente mientras que en la combinación con otras variables (en el análisis discriminante) tienen un alto poder de discriminación. Es preferible entonces realizar un análisis discriminante por pasos, con la adición gradual de nuevas variables explicativas. Sin embargo, este método tampoco asegura que se encuentre el mejor conjunto de variables explicativas [56].

Un análisis discriminante con fines de clasificación debe ser acompañado siempre o por la tasa de error aparente o aquella precisión resultante de validación cruzada. La tasa de error aparente cuantifica el % de datos mal clasificados, aunque subestima el error real ya que surge de aplicar la FDL a los mismos datos utilizados para generar la FDL. La validación cruzada, en cambio, se aplica en casos en los que se tienen suficientes datos y se puede particionar el conjunto de datos original en 2 conjuntos: uno utilizado para hallar la función discriminante y otro usado para la validación de la misma [57].

En el caso de clasificación de imágenes satelitales, el ADL puede ser pensado como una técnica de clasificación supervisada. Cada imagen satelital (o sus bandas) es una variable independiente métrica, los píxeles de las áreas de entrenamiento como elementos de los que se conoce la clase a la que pertenecen y en base a ellos se crean las FDL, y el resto de los píxeles como elementos de los que se desconoce al grupo al que pertenecen.

2.6.3. Precisión de las clasificaciones

La evaluación de la precisión consiste en el análisis del acuerdo entre una imagen tomada como verdadera (la imagen de referencia) y la imagen clasificada [58]. Es un modo de medir la calidad de las clasificaciones y de comparar entre distintas clasificaciones. Es importante no omitir este paso ya que la precisión afecta la validez legal de cartografía derivada de la teledetección, determina la posibilidad de ser usada en la toma de decisiones y condiciona su validez como base para la investigación científica [58].

Generalmente, la precisión alcanzable depende del detalle de la clasificación. Mientras más detalladas sean las clases, más probable es la ocurrencia de error [58].

Sin embargo, las medidas de precisión obtenidas durante estos análisis son medidas estadísticas. Los usuarios no deberían aceptar la validez de ningún mapa obtenido evaluando solamente sus valores de precisión, sino que deberían analizar también su origen y apariencia [58].

2.6.3.1. Matriz de confusión

Una manera estándar de informar errores de clasificación es mediante la matriz de confusión o de error. Esta consiste en un arreglo de dimensiones $n \times n$ donde n es el número de clases. Cada fila corresponde a los píxeles clasificados en cada clase mientras cada columna a los píxeles de cada clase en los datos de referencia. Los ejes son etiquetados con los nombres de las clases, y en la diagonal se encuentran las cantidades de píxeles bien clasificados.

Los totales de filas se encuentran en la columna del extremo derecho y se corresponden con la cantidad de píxeles de cada clase la imagen clasificada. Por el contrario, los totales de columnas se encuentran en el borde inferior e indican la cantidad de píxeles de cada clase en los datos de referencia.

Los valores fuera de la diagonal en cada columna representan *errores de omisión*, mientras que los valores fuera de la diagonal en las filas se corresponden con los errores de *errores de comisión* [58] [59]. Los primeros ocurren cuando píxeles dentro de una clase en los datos de referencia son etiquetados con otra clase en la imagen clasificada. Es decir, son “omitidos” en esta imagen. Por el contrario, los errores de comisión ocurren cuando píxeles son etiquetados con una clase que no es la misma que poseían en los datos de referencia. Por lo tanto, este error de comisión para una clase es error de omisión para otra [58]. A menudo, las matrices de confusión se construyen usando porcentajes más que el valor absoluto de píxeles [58].

2.6.3.2. Medidas de precisión

Las medidas más usadas para evaluar la precisión de imágenes clasificadas son la *precisión global* y el *índice Kappa*. La precisión global se define como la proporción de píxeles correctamente clasificados. Puede ser calculada según la Ec. 2.15:

$$PG = \frac{\sum \text{píxeles clasificados correctamente}}{\text{total de píxeles}} * 100 \quad (2.15)$$

Donde PG es la precisión global y va de 0 a 100, y *píxeles clasificados correctamente* es la suma de píxeles en la diagonal de la matriz de confusión.

Esta precisión global puede ser alcanzada por los efectos de la clasificación, pero también por efectos del azar en la asignación de clases a los píxeles. El *índice Kappa* entonces sustrae a la precisión global la proporción de acierto debida al azar, e indica cuánto mejor es la clasificación con respecto a la que puede ser obtenida por azar [60] [58] [59]. Este indicador puede ser estimado mediante las Ec. 2.16, 2.17 y 2.18 [59]:

$$K = \frac{p_g - p_a}{1 - p_a} \quad (2.16)$$

Donde p_g es la probabilidad de una clasificación correcta (es la precisión global) y p_a es la probabilidad de coincidencia por azar.

$$p_g = \frac{1}{N} \sum_{i=1}^M n_{ii} \quad (2.17)$$

Donde N es el número de píxeles, M el número de clases y n_{ii} una entrada en la matriz de confusión.

$$p_a = \sum_{i=1}^M \left\{ \frac{1}{N} \sum_{k=1}^M n_{ki} \sum_{k=1}^M n_{ik} \right\} \quad (2.18)$$

Donde N es la cantidad de píxeles, M la cantidad de clases.

CAPÍTULO 3

Área de estudio

El área de estudio de este trabajo de tesis es La Reserva Natural de la Defensa La Calera (RNDLC) (Fig. 3.1).

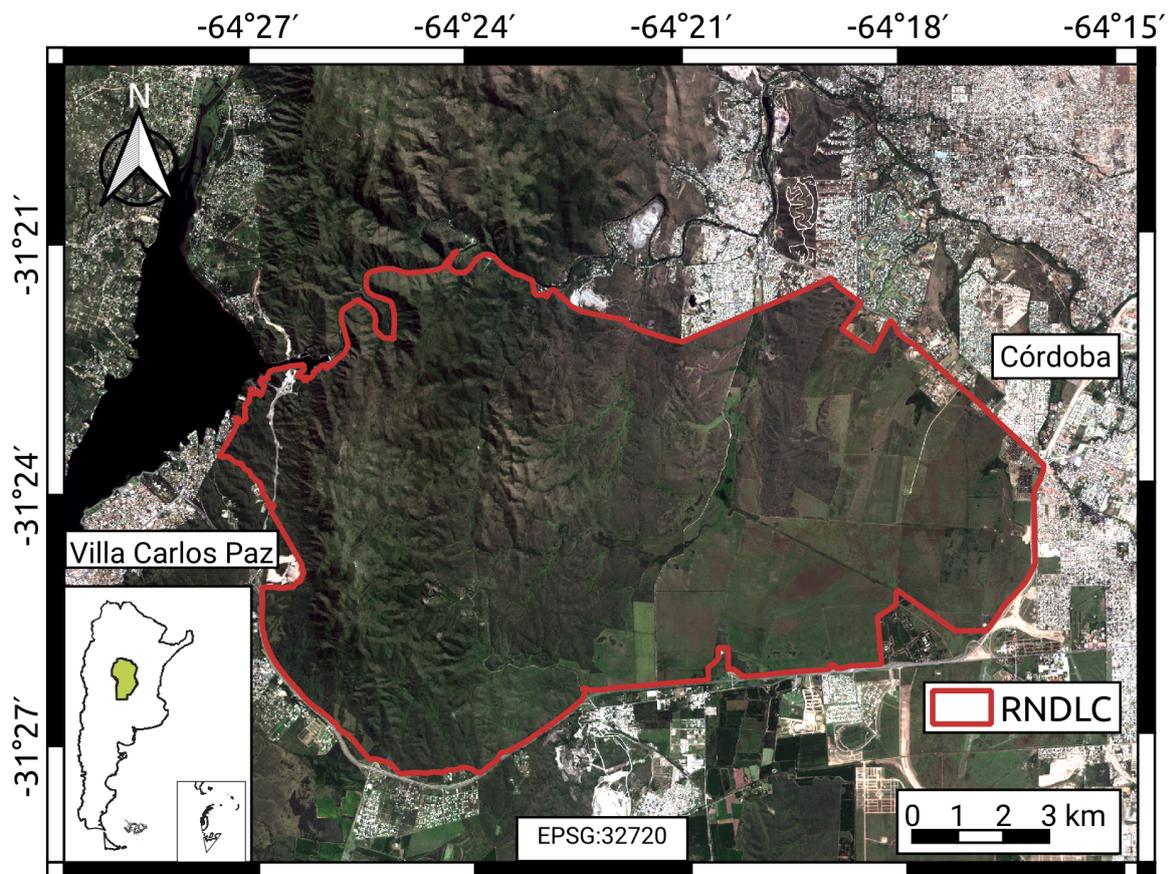


Figura 3.1: Reserva Natural de la Defensa La Calera (RNDLC)

Ésta es un área protegida inscrita en el Sistema Nacional de Áreas Protegidas (SNAP) cuyo objetivo es “conservar muestras representativas del gran mosaico ambiental que posee

Argentina". Es un área protegida desde el 3 de julio de 2009, día en que se firmó entre la administración de Parques Nacionales y el Ejército Argentino el Protocolo Adicional N° 5 [61]. Su superficie es de 13628 ha.

Los límites de la RNDLC son la Ruta Nacional N°20 hacia el Sur, la Ruta Provincial N°73 hacia el Oeste y el Norte, y parte del anillo de circunvalación de la Ciudad de Córdoba hacia el Este[22]. Las coordenadas geográficas extremas del predio son 31°27'23.37"S al Sur, 31°21'8.67"S al Norte, 64°27'28.58.º al Oeste, 64°16'2.56.º al Este .

En 1943 en esta área se encontraban estancias privadas que fueron expropiadas por el Ejército Nacional Argentino. Desde aquel momento, se restringió su ingreso para dedicarla a actividades militares. La zona Este (con pendientes menores al 5%) en las últimas décadas fue arrendada a particulares para la siembra de cultivos extensivos; en tanto que en la zona oeste (con pendiente media del 25%) se permitía la ganadería de subsistencia con baja carga animal.

En la actualidad, continúan las actividades de ganadería de subsistencia pero no las de agricultura extensiva. Estos lotes fueron clausurados en parte el 2009 (fecha de creación de la reserva) y otros en 2014, quizás por la presión del crecimiento urbano, la ley 9164 de la Provincia de Córdoba sobre aplicación de agroquímicos, y la creación de la reserva.

La conservación de esta reserva es fundamental por distintos motivos:

- Protege a la ciudad de Córdoba ante eventos de crecientes repentinas como de sequía. La vegetación existente permite que durante la estación húmeda se almacene gran cantidad de agua en el suelo que luego se va liberando progresivamente al río Suquía, principal curso de agua de la ciudad de Córdoba.
- Debido a su restricción de ingreso es un área representativa del espinal y chaco serrano.
- Es un corredor verde que une el Parque Nacional la Quebrada del Condorito y la Reserva Hídrica Provincial Pampa de Achala.
- Su valor histórico: allí se encuentran restos de asentamientos indígenas, caleras que se utilizaron para construir la Ciudad de Córdoba, las primeras usinas hidroeléctricas del país y allí funcionó el centro clandestino de detención más importante de Córdoba, La Perla, por lo que se investigan los posibles enterramientos clandestinos efectuados entre el año 1975 y 1983.

En esta Reserva, *El Cuenco-Equipo Ambiental* lleva a cabo en la RNDLC el proyecto "El manejo como herramienta de recuperación de cuenca" cuyo objetivo principal es estudiar y aplicar pautas de manejo para la conservación de los bosques y pastizales dentro de la reserva, con énfasis en la recuperación de especies vegetales nativas y control de exóticas, la preservación y recuperación de los ambientes fitogeográficos que lo componen.

3.1. Vegetación

La RNDLC se encuentra enmarcada en las Provincias Fitogeográficas Chaqueña al noroeste y Espinal al sureste. Dentro de la Provincia Chaqueña se encuentra en el Distrito Chaqueño serrano [62] dominado por bosques xerófilos alternados con estepas de gramíneas. Las especies arbóreas dominantes eran en 1976, según Cabrera (1976) [62] *Schinopsis lorentzii* (Griseb.) Engl., *Lithraea molleoides*, *Zanthoxylum coco* Gillies ex Hook. f. & Arn., *Vachellia caven* (Molina) Seigler & Ebinger, *Condalia microphylla* Cav., *Vachellia aroma* (Gillies ex

Hook. & Arn.) Seigler & Ebinger, *Aspidosperma quebracho-blanco* Schltdl., *Prosopis torquata* (Cav. ex Lag.) DC., *Monteverdia spinosa* (Griseb.) Biral, *Jodina rhombifolia* (Hook. & Arn.) Reissek y *Ruprechtia apetala* Wedd.

Dentro del Espinal se encuentra el distrito del Algarrobo que recorre la provincia de Córdoba en forma de banda diagonal de noreste a sudoeste. Cabrera (1976) [62] lo caracterizaba en 1976 como el menos conocido de la provincia del Espinal por su escasa representatividad debido a la explotación agrícola y desmonte; situación que sin duda se ha agudizado desde aquel entonces a la actualidad. El bosque de esta región es xerófilo y su comunidad clímax según Cabrera (1976) [62] está dominada por *Prosopis nigra* (Griseb.) Hieron. var. *nigra*, *Prosopis alba* Griseb. var. *alba*, *Celtis tala* (Jacq.) Sarg., *Celtis pallida* Torr., *Geoffroea decorticans* (Gillies ex Hook. & Arn.) Burkart, *Vachellia caven* (Molina) Seigler & Ebinger, *Jodina rhombifolia* (Hook. & Arn.) Reissek, *Schinus fasciculatus* (Griseb.) I.M. Johnst., *Monteverdia spinosa* (Griseb.) Biral.

Karlin et al. (2014) [22] entre Junio de 2012 y Febrero de 2013 relevaron la composición florística de la RNDLC con el objetivo de identificar zonas homogéneas para el manejo y conservación. Describen a la vegetación presente agrupada en 6 comunidades:

- Quebrachales: Se ubican en las zonas bajas e intermedias de la reserva, hasta los 570 m.s.n.m. Están dominados por *Aspidosperma quebracho-blanco* Schltr. y se agrupan en parches de adultos en las áreas de antiguo uso agrícola o renovales dispersos fuera de los parches pero cercanos a éstos. Esto sugiere que pueden tener una gran capacidad de recuperación.
- Blanquillales: Está dominada por *Sebastiania commersoniana* (Baill.) L.B. Sm. & Downs, asociada a cursos de agua permanentes o temporarios o en laderas expuestas a precipitaciones. Se asocian a especies exóticas invasoras como mora (*Morus alba* L.), siempre verde (*Ligustrum lucidum* W.T.Aiton) y cafeto (*Manihot grahamii* Hook) que generan bosques densos con alta cobertura de suelo, lo que no permite el desarrollo de otras especies en el sotobosque.
- Mollales: Se ubican sobre zonas rocosas aumentando su frecuencia al ascender topográficamente. Están dominados por *Lithraea molleoides* (Vell.) Engl. Pueden estar asociadas a blanquillos en las inmediaciones de cursos de agua.
- Espinillales: Se desarrollan en laderas a sotavento, por lo que reciben menor cantidad de lluvia y humedad y son afectados por incendios. Están dominados por *Vachellia aroma* (Gillies ex Hook. & Arn.) Seigler & Ebinger principalmente y *Vachellia caven* (Molina) Seigler & Ebinger en menor medida, además de poáceas como *Jarava pseudoichu* Ruiz y Pav. var. *ichu* y *Amelichloa brachychaeta* (Godr.) Arriaga y Barkworth.
- Horcales: Se encuentran en las laderas a barlovento. Están dominados por *Schinopsis lorentzii* Engl. Individuos grandes y renovales de esta especie se encontraron en gran cantidad, lo que sugiere que sufren menor intensidad y frecuencia de disturbios y se encuentran en recuperación.
- Pastizales: factores como cursos de agua, intensidad de pastoreo, incendios y tipo de suelo determinan su fisionomía, encontrándose dos tipos: A) pastizales con especies saxícolas, dominados por *Jarava pseudoichu* var. *ichu* y *Amelichloa brachychaeta*, y B) pastizales de zonas riparias, dominados por *Cynodon dactylon* (L.). Ambos pueden presentar asociados bosquecillos pequeños de chañar (*Geoffroea decorticans* (Gillies ex Hook. & Arn.) Burkart)

3.2. Clima

La precipitación media anual es de 800 mm, de los cuales 640 mm están concentrados en el periodo estival (Fig. 3.2). La temperatura media anual es de 16 °C, la máxima media anual de 24 °C y la mínima media anual de 10,1 °C. La máxima absoluta histórica alcanza los 44°C y la mínima absoluta es de -10°C [63]. Predominan los vientos del noreste y sur-sureste, de los cuales los primeros son cálidos y secos y los segundos son frescos y húmedos [64].

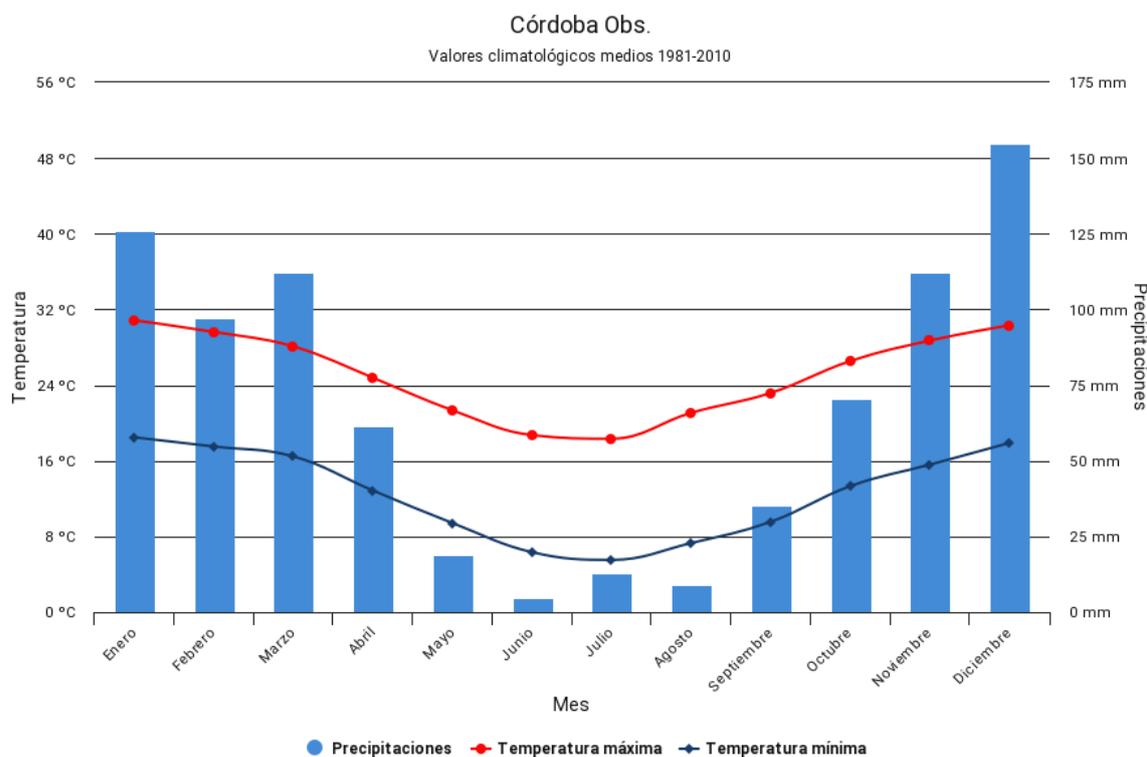


Figura 3.2: Climograma estación Observatorio

Fuente: Servicio Meteorológico Nacional. <https://www.smn.gov.ar/estadisticas> Acceso: 12/04/2019

3.3. Suelo

Gorgas et al. (2003)[65] describieron en la RNDLC 3 unidades cartográficas a nivel de reconocimiento 1:500000. (Fig. 3.1)

Tabla 3.1: Unidades cartográficas RNDLC

	EPLi-9	EPLi-17	MKtc-2
IP	1	5	61
Aptitud de uso	VII	VII	III
Fisiografía	Sierras Chicas	Sierras Chicas	Depresión periférica

IP: índice de productividad.

Las unidades EPLi-9 y EPLi-17 se encuentran en la unidad geomorfológica de Sierras Chicas y no son aptos para agricultura (Aptitud de uso clase VII). Los suelos que las componen son Ustortent lítico paralítico, Ustortent lítico y en menor medida Haplustol fluvéntico. Son suelos no aptos para agricultura, de escaso desarrollo en profundidad, pobres en materia orgáni-

ca, deficientes en retención de humedad y capacidad de intercambio, con elevada pendiente y pedregosos en algunos casos. Son altamente susceptibles a erosión hídrica.

La unidad MKtc-2 está en la depresión periférica. Se compone de Argiustol típico y Haplustol éntico. Éstos son suelos aptos para la agricultura (Aptitud de uso clase III), profundos, bien drenados, provistos de materia orgánica, moderada a alta capacidad de intercambio, ligera a moderadamente susceptibles a erosión hídrica en función de su pendiente. Coincide con los lotes que fueron arrendados para prácticas de agricultura extensiva hasta el 2009 y 2012.

Los suelos dentro del ejido municipal de la Ciudad de Córdoba no fueron caracterizados y se incluyen dentro de la categoría misceláneas.

Karlin et al. [66] realizaron un nuevo mapa de suelos de la RNDLC a nivel 1:5000 (Fig. 3.3) a partir de información geológica y geomorfológica, mapas topográficos y de vegetación, calicatas y chequeos a campo. Encontraron suelos representantes de las unidades geomorfológicas de Sierras Chicas, Depresión Periférica y Pampa Limo Loessica, ésta última en el sector clasificado como misceláneas por Gorgas et al. (2003) [65]. Utilizaron el protocolo de taxonomía de suelos Soil Survey Taxonomy, en el que las subclases paralítica y lítica se han unificado en los Ustortent líticos. En la unidad EPLi-17 además encontraron Haplustoles fluvénticos, y en la MKtc-2 Haplustoles típicos y énticos en el área clasificada por Gorgas et al. (2003) [65] como misceláneas.

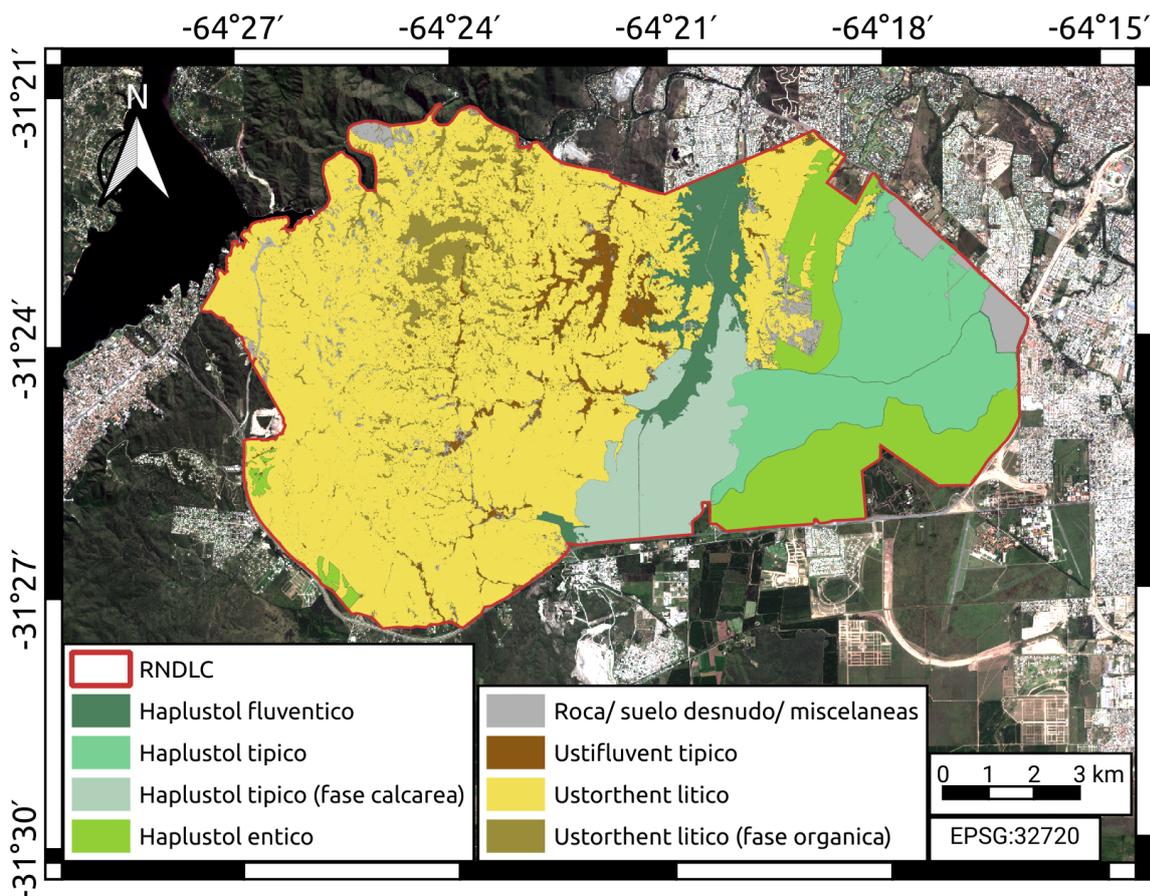


Figura 3.3: Unidades taxonómicas de suelo de la RNDLC

Fuente: Adaptado de Karlin et. al [66]

Debido a la menor escala de trabajo utilizada, también pudieron reconocer fases: Fase orgánica de los Ustorthents líticos y la fase calcárea de los Haplustoles típicos. El origen de

la fase orgánica se atribuye al tipo de vegetación, se trata de comunidades de *Sebastiania commersoniana* formadoras de suelo en vías de escurrimiento con afloramientos rocosos. La fase calcárea en tanto no tiene influencia ambiental, es consecuencia del desarrollo de material parental en la Depresión periférica. En estos suelos la ligera cementación con carbonatos de calcio mejora la estructura y porosidad, volviéndolos muy buenos desde el punto de vista físico.

Encontraron que la vegetación está íntimamente relacionada con los tipos de suelo, por lo que caracterizar las propiedades edáficas de cada suelo permite establecer cuáles son las condiciones bajo las cuales se desarrollan las diferentes comunidades vegetales.

4.1. Datos de campo

El conjunto de datos de campo fue obtenido mediante censos de vegetación con el método fitosociológico de Braun Blanquet [67] dentro de la superficie cubierta por las categorías de “Bosque denso” y “Bosque abierto” de Karlin et al. (2014)[22]. Estos censos fueron realizados entre el 2012 y 2018 en la Reserva Natural de la Defensa La Calera(RNDLC). La metodología es descrita en Karlin et al. (2014) [22]. La ubicación de los datos de campo se muestra en la Fig. 4.1.

Fueron definidas 3 clases llamadas *L. lucidum* (lluc), *Nativas* (nat) y *Mixto* (mix), basadas en la cobertura boscosa de las especies *Ligustrum lucidum* (LL), *Lithraea molleoides* (LM) y *Sebastiania commersoniana* (SC). Se entiende a la cobertura boscosa como el porcentaje de suelo cubierto por la proyección vertical de la copa de los árboles [67]. Las tres clases se definen a continuación y en la Tabla 4.1:

- *L. lucidum* (lluc): Se trata de bosques bien cerrados, sombreados, con poca cobertura de herbáceas (Figs. 4.2a y 4.2b). Aquí se incluyen dos tipos de sitios.
 - Áreas con cobertura boscosa de *Ligustrum lucidum* y sin cobertura de *Lithraea molleoides* y *Sebastiania commersoniana*.
 - Áreas en que la cobertura boscosa de *Ligustrum lucidum* supere en al menos un 25 % a la cobertura sumada de *Lithraea molleoides* más *Sebastiania commersoniana*.

Fueron identificados 16 polígonos de esta clase, que suman un total de 75 píxeles de resolución espacial de 10 m.

- *Nativas* (nat): Los bosques de Blanquillo (Fig. 4.3a) se encuentran predominantemente en los márgenes de arroyos, permiten el paso de luz a través de las copas, muestran presencia de herbáceas cubiendo el suelo (Fig. 4.3b). En la figura 4.3c se observa que a medida que aumenta la distancia (y la altitud) desde los arroyos, predominan los bosques de *Lithraea molleoides*. Los sitios incluídos en esta clase son:

4.1 DATOS DE CAMPO

- Áreas con cobertura boscosa de *Lithraea molleoides* o *Sebastiania commersoniana* y sin cobertura de *Ligustrum lucidum*.
- Áreas en que la cobertura boscosa sumada de *Lithraea molleoides* y *Sebastiania commersoniana* supere en al menos un 25 % a la cobertura de *Ligustrum lucidum*.

Fueron identificados 11 polígonos de esta clase, que abarcan 82 píxeles de resolución espacial de 10 m.

- Mixto (mix): Se trata de situaciones intermedias. Aún hay algo de paso de luz que permite el crecimiento de herbáceas en el sotobosque (Figs. 4.4a y 4.4b), aunque en muchos casos esa superficie ya fue ocupada por renovales de siempreverde (Fig. 4.4c). Esta clase incluye áreas con igual cobertura boscosa de *Ligustrum lucidum* y de *Lithraea molleoides* más *Sebastiania commersoniana*; ó con diferencia entre ellos menor al 25 %.

Fueron identificados 16 polígonos de esta clase, que suman un total de 67 píxeles de resolución espacial de 10 m.

Tabla 4.1: Datos de campo: clases

LL	LM+SC	$LL > (LM+SC) + 25\%$	$(LM+SC) > LL + 25\%$	Clase
Si	No			lluc
Si	Si	Si		lluc
No	Si			nat
Si	Si		Si	nat
Si	Si	No	No	mix

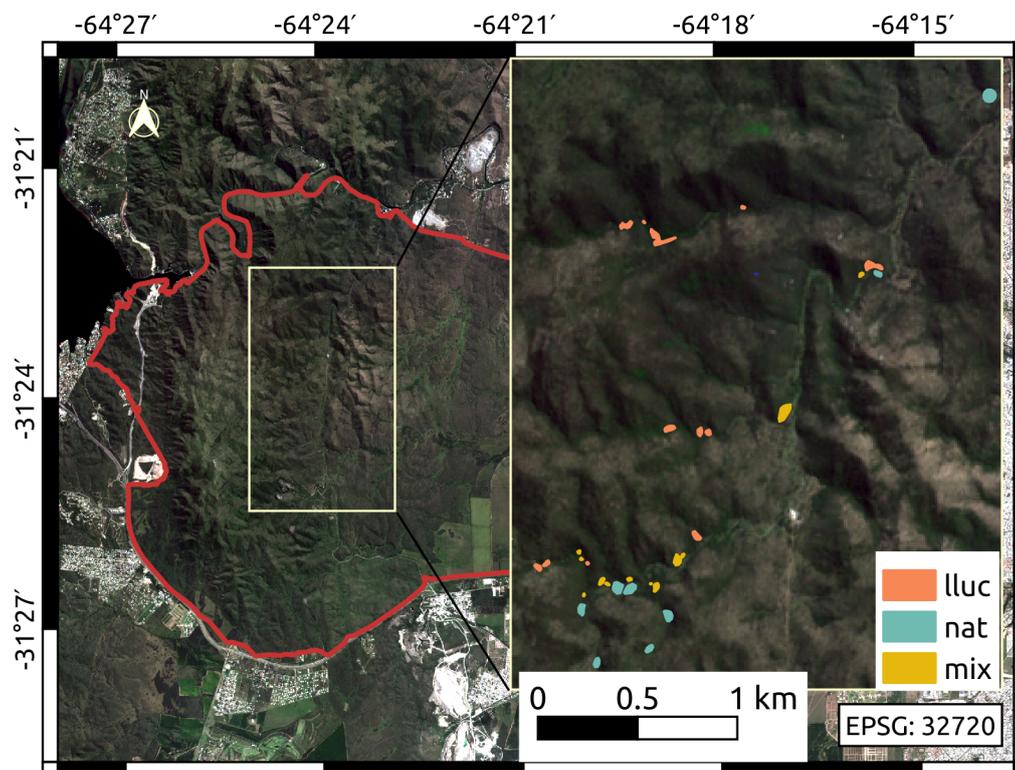


Figura 4.1: Ubicación de sitios de muestreo



(a)



(b)

Figura 4.2: Fotografías clase *lluc*



(a)



(b)



(c)

Figura 4.3: Fotografías clase *nat*



Figura 4.4: Fotografías clase *mix*

4.2. Descarga y procesamiento de imágenes

4.2.1. Datos SAR

Se emplearon imágenes de la misión Sentinel-1, que fueron descargadas de manera automática del catálogo de la Agencia Espacial Europea (ESA), por personal del Instituto de Observación de la Tierra-EURAC Research. De todas las imágenes disponibles para el área de estudio del año 2018, sólo fueron seleccionadas aquellas de la plataforma Sentinel-1B (ver detalle en Tabla 4.2). Por el contrario, de la plataforma Sentinel-1A sólo fueron adquiridas imágenes sobre el área de estudio durante Enero y Junio, motivo por el cual no pudieron ser utilizadas.

Las imágenes seleccionadas están equiespaciadas en el tiempo cada doce días, pertenecen a la órbita relativa 112, fueron adquiridas con el modo “*Interferometric Wide swath*”, son productos de tipo “*Single Look Complex*”, con nivel de procesamiento 1, clase de producto estándar, polarización dual VV+VH y pasada descendente.

Tabla 4.2: Imágenes S1B seleccionadas

Nombre del producto	Fecha
S1B_IW_SLC__1SDV_20180107T093754_20180107T093821_009063_010334_E18B	07/01/2018
S1B_IW_SLC__1SDV_20180119T093754_20180119T093821_009238_0108E5_EB01	19/01/2018
S1B_IW_SLC__1SDV_20180131T093753_20180131T093820_009413_010EA1_A11D	31/01/2018
S1B_IW_SLC__1SDV_20180212T093812_20180212T093839_009588_01146C_1C5A	12/02/2018
S1B_IW_SLC__1SDV_20180224T093753_20180224T093820_009763_011A2C_1816	24/02/2018
S1B_IW_SLC__1SDV_20180308T093753_20180308T093820_009938_012009_BD50	08/03/2018
S1B_IW_SLC__1SDV_20180320T093753_20180320T093820_010113_0125BE_5EFB	20/03/2018
S1B_IW_SLC__1SDV_20180401T093754_20180401T093821_010288_012B68_2EEE	01/04/2018
S1B_IW_SLC__1SDV_20180413T093754_20180413T093821_010463_013117_EB93	13/04/2018
S1B_IW_SLC__1SDV_20180425T093754_20180425T093821_010638_0136A5_66AE	25/04/2018
S1B_IW_SLC__1SDV_20180507T093755_20180507T093822_010813_013C4E_3A83	07/05/2018
S1B_IW_SLC__1SDV_20180519T093756_20180519T093823_010988_0141F3_3DC4	19/05/2018
S1B_IW_SLC__1SDV_20180531T093756_20180531T093823_011163_0147A8_855D	31/05/2018
S1B_IW_SLC__1SDV_20180612T093757_20180612T093824_011338_014D1D_D0FB	12/06/2018
S1B_IW_SLC__1SDV_20180624T093758_20180624T093825_011513_015287_B4E3	24/06/2018
S1B_IW_SLC__1SDV_20180706T093759_20180706T093826_011688_0157FE_9A92	06/07/2018
S1B_IW_SLC__1SDV_20180718T093759_20180718T093826_011863_015D5F_E9D3	18/07/2018
S1B_IW_SLC__1SDV_20180730T093800_20180730T093827_012038_0162A5_B3A4	30/07/2018
S1B_IW_SLC__1SDV_20180811T093801_20180811T093828_012213_016808_1EB2	11/08/2018
S1B_IW_SLC__1SDV_20180823T093801_20180823T093828_012388_016D6F_A562	23/08/2018
S1B_IW_SLC__1SDV_20180904T093802_20180904T093829_012563_0172DF_D702	04/09/2018
S1B_IW_SLC__1SDV_20180916T093802_20180916T093829_012738_017838_F068	16/09/2018
S1B_IW_SLC__1SDV_20180928T093803_20180928T093830_012913_017D9A_3278	28/09/2018
S1B_IW_SLC__1SDV_20181010T093803_20181010T093830_013088_0182ED_8673	10/10/2018
S1B_IW_SLC__1SDV_20181022T093815_20181022T093842_013263_018855_A557	22/10/2018
S1B_IW_SLC__1SDV_20181103T093803_20181103T093830_013438_018DD8_0428	03/11/2018
S1B_IW_SLC__1SDV_20181115T093803_20181115T093830_013613_019348_01E8	15/11/2018
S1B_IW_SLC__1SDV_20181127T093802_20181127T093829_013788_0198DD_866C	27/11/2018
S1B_IW_SLC__1SDV_20181209T093802_20181209T093829_013963_019E8C_1C66	09/12/2018
S1B_IW_SLC__1SDV_20181221T093802_20181221T093829_014138_01A44A_1606	21/12/2018

4.2.1.1. Coeficiente de retrodispersión

Se procesaron las 30 imágenes de Sentinel 1B (detalle en Tabla 4.2) mediante las herramientas de procesamiento de grafo de SNAP (Graph processing tool, en inglés), dentro de un programa de Python 3.6.7 como muestra el diagrama de flujo de la Fig. 4.6. El producto final fueron 2 series temporales con polarización VH o VV, de 30 imágenes de coeficiente de retrodispersión en dB, equiespaciadas a doce días.

Para cada imagen, el procesamiento consistió en los siguientes pasos:

- Mediante la herramienta *TOPSAR Split* se seleccionó el segundo swath, dado que es el que contiene el área de interés.
- Se aplicó el archivo de órbita precisa mediante la herramienta *Apply Orbit file*.
- Mediante la herramienta *Calibration* se calibró a coeficiente de retrodispersión .
- Con la herramienta *TOPSAR deburst* se unieron en una misma imagen los 9 bursts del swath seleccionado.
- Mediante las herramientas *Back Geocoding* y *Enhanced Spectral Diversity* se corrigió con la imagen del 18/07/2018. Se eligió a esta imagen como máster ya que se

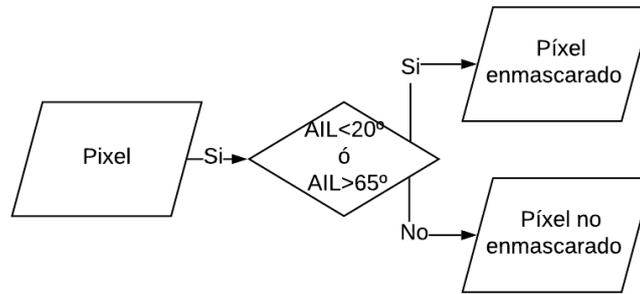


Figura 4.5: Diagrama de enmascaramiento por sombra o inversión (*layover*)

AIL: Ángulo de incidencia local

presume que es de buena calidad por ausencia de nubes, por ser del periodo seco en la región. De este modo, se garantiza una mejor precisión en la corrección. La ausencia de precipitación en ese día se corroboró con información de precipitación de la Bolsa de Cereales de Córdoba para la estación meteorológica de Alta Gracia. El DEM utilizado en la corrección fue el SRTM 1 Sec HGT. El producto resultante es un grupo compuesto por la imagen máster (aquella del 18/07/2018) y la imagen esclava.

- Se agrupó a cada producto de corrección con los productos de corrección de la imagen anterior y posterior, mediante la herramienta *Create-Stack*.
- Con *Band Select* se seleccionó del grupo anterior sólo a las imágenes esclavas de los productos de corrección. Se obtuvo entonces un grupo de 3 imágenes consecutivas, todas corregidas con la misma imagen máster del 18/07/2018.
- Con el producto del paso anterior, se aplicó el filtro multitemporal de reducción de ruido speckle (*Multi Temporal Speckle Filter*) a la imagen central, con aportes de la imagen precedente y posterior. Se utilizó el filtro Lee con ventana de 3x3.
- Se compensaron las distorsiones geométricas que se generan debido a la visión lateral del sensor mediante la herramienta *Range Doppler Terrain Correction*. Se utilizó también el DEM SRTM 1 Sec HGT, descargado automáticamente por SNAP al emplear esta herramienta. Se guardó en una banda del producto resultante información correspondiente al ángulo de incidencia local, que fue utilizada en el paso siguiente.
- Fueron enmascarados aquellos píxeles que tenían distorsiones geométricas por sombra o inversión (*layover*). Estos fueron identificados como aquellos que estaban en áreas con ángulo de incidencia local (AIL) menor a 20° o mayor a 65°, respectivamente, como muestra la Fig. 4.5.

El conjunto de las 30 imágenes procesadas, ordenadas cronológicamente, fue agrupado en un mismo archivo, pero distinguiendo entre aquellas con polarización VH de aquellas con VV. Luego los valores de coeficiente retrodispersión en potencia ($\sigma_{(pot)}^0$) de cada imagen fueron transformados a decibeles ($\sigma_{(dB)}^0$) mediante la Ec. 4.1. Estos grupos de imágenes se mencionan de ahora en adelante como series temporales de coeficiente de retrodispersión (CR) en polarización VH o VV.

$$\sigma_{(dB)}^0 = 10 \log_{10} \sigma_{(pot)}^0 \quad (4.1)$$

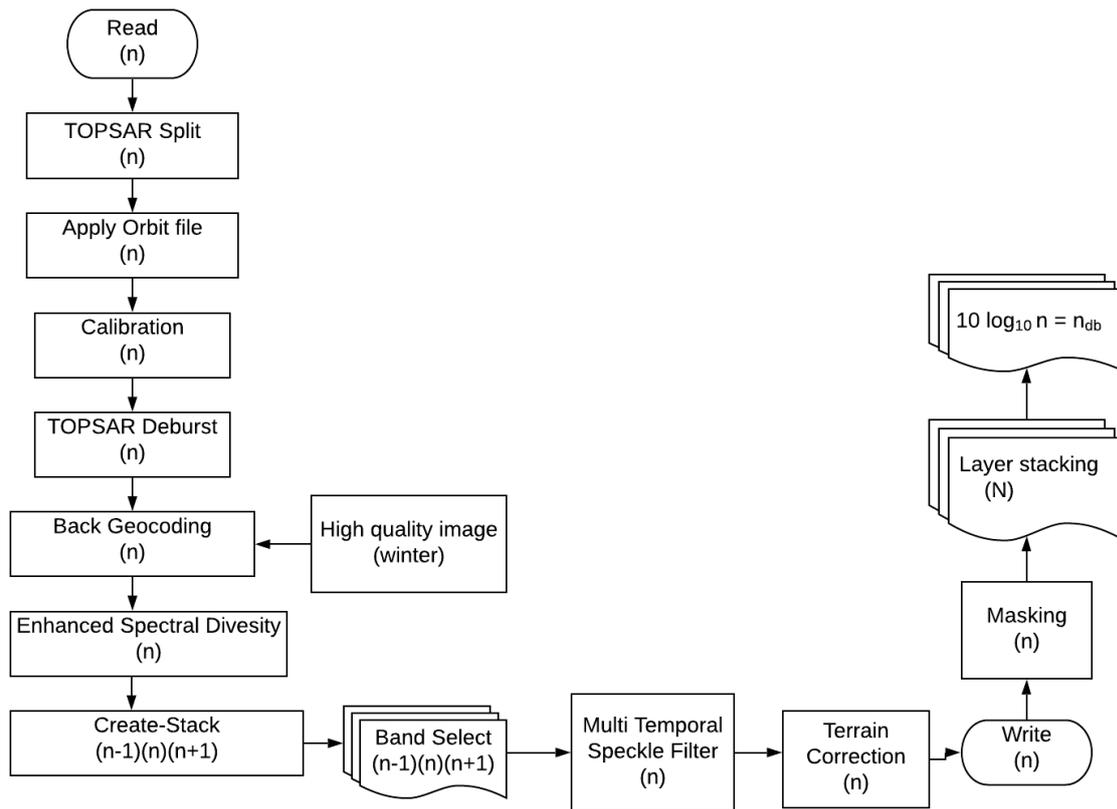


Figura 4.6: Diagrama de flujo Coeficiente de Retrodispersión

4.2.1.2. Coherencia

Fue estimada la coherencia interferométrica entre cada imagen y la imagen siguiente del conjunto detallado en la Tabla 4.2. Los 29 intervalos de estimación de coherencia se muestran en la tabla 4.3.

Tabla 4.3: Intervalos de estimación de coherencia interferométrica

Fechas de intervalos de estimación de coherencia		
07/01-19/01	07/05-19/05	04/09-16/09
19/01-31/01	19/05-31/05	16/09-28/09
31/01-12/02	31/05-12/06	28/09-10/10
12/02-24/02	12/06-24/06	10/10-22/10
24/02-08/03	24/06-06/07	22/10-03/11
08/03-20/03	06/07-18/07	03/11-15/11
20/03-01/04	18/07-30/07	15/11-27/11
01/04-13/04	30/07-11/08	27/11-09/12
13/04-25/04	11/08-23/08	09/12-21/12
25/04-07/05	23/08-04/09	

El procesamiento fue llevado a cabo con las herramientas de procesamiento de grafo de SNAP (Graph processing tool, en inglés), dentro de un programa de Python 3.6.7. Cada paso fue ejecutado de manera individual y no dentro de un grafo, con el objetivo de reducir el

consumo de memoria RAM. En el Anexo B se adjunta el código de Python ejecutado para realizar el procesamiento. Los pasos se grafican en el diagrama de flujo de la Fig. 4.7 y se describen a continuación:

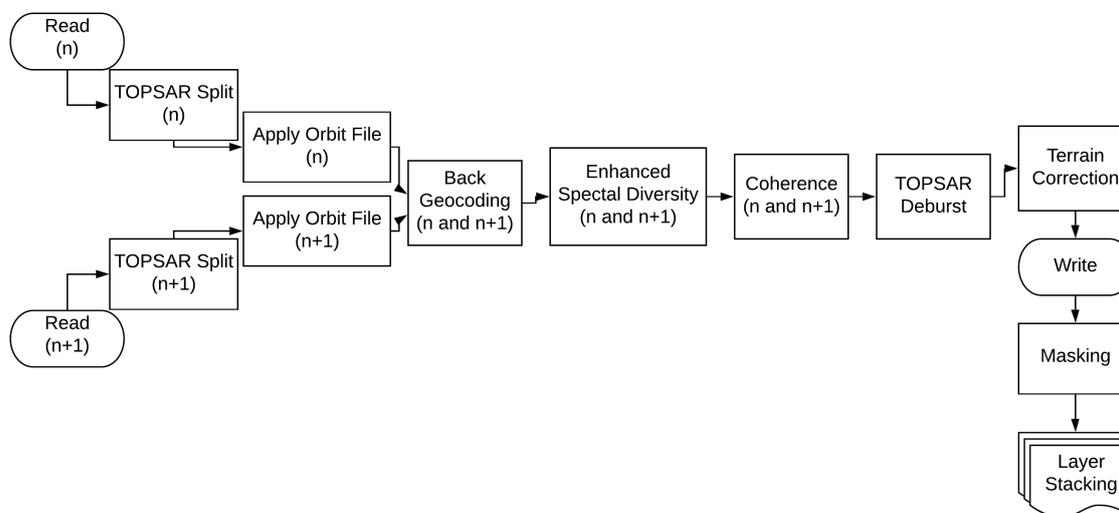


Figura 4.7: Diagrama de flujo estimación de coherencia interferométrica

- **División:** Con la herramienta *TOPSAR split* se eligió en cada imagen el subswath número dos, porque es el que contiene al área de estudio. Se seleccionaron todos los bursts y las dos polarizaciones (VH y VV).
- **Aplicación de órbita precisa:** Se aplicó la órbita precisa para cada imagen con el método polinomial de grado 3.
- **Corregistración:** Se realizó entre los productos del paso anterior de cada imagen con el de la imagen posterior. Se empleó la herramienta *Back-Geocoding*, con el Modelo Digital de Elevación de SRTM 1Sec HGT y se realizó para los productos de polarización VH y VV.
- **Mejora de la corrección:** Se empleó el *Enhanced spectral diversity*, con los parámetros sugeridos por defecto por SNAP.
- **Estimación de la coherencia interferométrica:** Se realizó para cada producto del paso anterior, para cada una de las polarizaciones. Se usó una ventana de estimación de 19x5 en rango y azimuth, respectivamente.
- **Unión de los bursts:** Mediante *TOPSAR-Deburst* fueron unidos los bursts de los productos de estimación de coherencia obtenida en el paso anterior, para cada polarización.
- **Corrección de terreno:** Se empleó la herramienta *Range Doppler Terrain Correction*, con el DEM de SRTM 1Sec y coordenadas WGS84.
- En cada producto, fueron enmascarados aquellos píxeles con distorsiones geométricas por sombra o inversión (layover). Estos fueron identificados como aquellos que estaban en áreas con ángulo de incidencia local (AIL) menor a 20° o mayor a 65°, respectivamente, como muestra la Fig. 4.5.

El conjunto de los 29 productos de estimación de coherencia interferométrica con cada polarización (VH o VV), ordenado cronológicamente, fue agrupado en un mismo archivo. Estos archivos se mencionan desde ahora como series temporales de estimación de coherencia interferométrica (Coh) en polarizaciones VH o VV.

4.2.2. Datos ópticos

Se emplearon imágenes de la misión Sentinel-2, que fueron descargadas de manera automática del catálogo de la Agencia Espacial Europea (ESA), por personal del Instituto de Observación de la Tierra-EURAC Research. Todas fueron tomadas por los sensores MSI, pertenecen a la escena 20JLL y están en nivel de procesamiento 1C, es decir, en reflectancia a tope de atmósfera.

Del total de 140 imágenes disponibles para el área de estudio para el año 2018, se seleccionaron las de mejor calidad sobre el área de estudio para cada intervalo de estimación de coherencia de la Tabla 4.3. Se consideró como imagen de mejor calidad a la que tuviera menor presencia de nubes. Esta valoración se hizo de modo visual. El objetivo de elegir imágenes dentro de estos intervalos fue poder comparar luego entre series temporales de productos derivados de imágenes SAR y ópticas. Las imágenes seleccionadas se detallan en la tabla 4.4.

Tabla 4.4: Imágenes S2 seleccionadas

El nombre de cada intervalo de estimación de coherencia corresponde a día y mes de la fecha de inicio y de la fecha final del intervalo. Todos los intervalos corresponden a 2018.

Intervalo de estimación de coherencia	Imagen de Sentinel-2
07/01-19/01	S2B_MSIL1C_20180103T142029_N0206_R010_T20JLL_20180103T173024
19/01-31/01	(04/02/2018+03/01/2018)/2
31/01-12/02	S2A_MSIL1C_20180204T141041_N0206_R110_T20JLL_20180204T173445
12/02-24/02	S2B_MSIL1C_20180222T142029_N0206_R010_T20JLL_20180222T205741
24/02-08/03	S2B_MSIL1C_20180301T141039_N0206_R110_T20JLL_20180301T190720
08/03-20/03	S2A_MSIL1C_20180319T142031_N0206_R010_T20JLL_20180319T174257
20/03-01/04	S2A_MSIL1C_20180329T142041_N0206_R010_T20JLL_20180329T174533
01/04-13/04	S2A_MSIL1C_20180405T141051_N0206_R110_T20JLL_20180405T173634
13/04-25/04	S2B_MSIL1C_20180420T141049_N0206_R110_T20JLL_20180420T173053
25/04-07/05	(20/05/2018-20/04/2018)/3*1+20/04/2018
07/05-19/05	(20/05/2018-20/04/2018)/3*2+20/04/2018
19/05-31/05	S2B_MSIL1C_20180520T141049_N0206_R110_T20JLL_20180520T173536
31/05-12/06	S2A_MSIL1C_20180607T142041_N0206_R010_T20JLL_20180607T174621
12/06-24/06	S2B_MSIL1C_20180619T141049_N0206_R110_T20JLL_20180619T172809
24/06-06/07	S2B_MSIL1C_20180629T141049_N0206_R110_T20JLL_20180629T155825
06/07-18/07	S2B_MSIL1C_20180712T142039_N0206_R010_T20JLL_20180712T192200
18/07-30/07	S2A_MSIL1C_20180724T141051_N0206_R110_T20JLL_20180724T173505
30/07-11/08	S2A_MSIL1C_20180806T142041_N0206_R010_T20JLL_20180806T180757
11/08-23/08	S2B_MSIL1C_20180821T142029_N0206_R010_T20JLL_20180821T194406
23/08-04/09	S2B_MSIL1C_20180828T141039_N0206_R110_T20JLL_20180828T194244
04/09-16/09	S2B_MSIL1C_20180907T141039_N0206_R110_T20JLL_20180907T190957
16/09-28/09	S2B_MSIL1C_20180920T142029_N0206_R010_T20JLL_20180920T193621
28/09-10/10	S2B_MSIL1C_20181010T142039_N0206_R010_T20JLL_20181010T193957
10/10-22/10	S2A_MSIL1C_20181015T142031_N0206_R010_T20JLL_20181015T185654
22/10-03/11	(14/11/2018+15/10/2018)/2
03/11-15/11	S2A_MSIL1C_20181114T142031_N0207_R010_T20JLL_20181114T175244
15/11-27/11	S2B_MSIL1C_20181119T142039_N0207_R010_T20JLL_20181119T174805
27/11-09/12	S2A_MSIL1C_20181124T142031_N0207_R010_T20JLL_20181124T173722
09/12-21/12	S2A_MSIL1C_20181214T142031_N0207_R010_T20JLL_20181214T173648

Para los intervalos en que no había disponibilidad de imágenes sin nubes (19/01-31/01, 25/04-07/05, 07/05-19/05, 22/10-03/11), se generaron por interpolación lineal como se especifica en la sección 4.2.2.1

Dado que imágenes de la Tabla 4.4 fueron descargadas en nivel de procesamiento 1C, contienen información de reflectancia a tope de atmósfera. Por lo tanto, debieron ser corregidas atmosféricamente para obtener datos de reflectancia en superficie. Este procesamiento se realizó mediante la herramienta *Sen2Cor* propuesta por la Agencia Espacial Europea (ESA), que genera como producto imágenes de nivel de procesamiento 2A. La ejecución se realizó de manera automática mediante un programa en Python creado con este fin.

Para las bandas de Sentinel-2 (B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12) se construyeron las series temporales de reflectancia agrupando en un mismo archivo a las 29 imágenes correspondientes a cada banda.

4.2.2.1. Cálculo de NDVI

Para cada imagen de la Tabla 4.4, ya corregida atmosféricamente, se calculó el NDVI con las bandas 8 y 4 (según Ec. 4.2), con resolución espacial de 10 m. El cálculo se realizó de

manera automática con un programa de Python generado para este fin, adaptado de Cole, Krehbiel(2017) [68].

$$NDVI = \frac{Banda_8 - Banda_4}{Banda_8 + Banda_4} \quad (4.2)$$

Los NDVI de los intervalos de estimación de coherencia en los que no se disponía de imágenes sin cobertura nubosa sobre el área de estudio (19/01-31/01, 25/04-07/05, 07/05-19/05, 22/10-03/11), fueron generados por interpolación lineal entre los NDVI de la imagen de los intervalos anterior y posterior.

El conjunto de las 29 imágenes de NDVI, ordenado cronológicamente, fue agrupado en un mismo archivo que será nombrado desde ahora como serie temporal de NDVI.

4.3. Análisis descriptivo de series temporales

Se graficaron las series temporales promedio de coeficiente de retrodispersión en VH y en VV, de estimación de coherencia en VH y en VV y de NDVI para los datos de campo de cada clase. Además, a estos gráficos se agregaron las series temporales de temperatura y precipitaciones con datos a intervalos de tiempo de 10 minutos de la *Bolsa de Cereales de Córdoba* para la estación meteorológica de Alta Gracia. Para los gráficos de coherencia interferométrica y NDVI se promediaron las temperaturas y se sumaron las precipitaciones caídas entre el primer y el último día del intervalo de estimación de coherencia; mientras que para los gráficos de coeficiente de retrodispersión los promedios y sumas se hicieron entre la fecha de la imagen anterior y la fecha de la imagen en cuestión.

Para cada variable, en todas las fechas se realizaron pruebas de hipótesis de diferencias de medias entre las series temporales promedio de cada clase según el diagrama de flujo de la Fig. 4.8. La elección de la prueba de diferencia de medias se llevó a cabo en base a los supuestos de normalidad y homogeneidad de varianzas. La evaluación del supuesto de normalidad de las distribuciones se llevó a cabo mediante la prueba de Shapiro-Wilks sobre los residuos estandarizados del ANOVA con cada clase como factor. La evaluación del supuesto de homogeneidad de varianzas, mientras tanto, se llevó a cabo mediante la prueba de Levene para variables con distribución normal o mediante la prueba de Fligner para variables sin distribución normal. La diferencia estadística entre medias se evaluó entonces para variables:

- a) Con distribución normal y varianzas homogéneas: Se emplearon el ANOVA y la prueba de Tukey para variables con distribución normal (Fig. 4.8).
- b) Con distribución normal y varianzas no homogéneas: Se observó la superposición de cinturas de los boxplots (Fig. 4.8).
- c) Sin distribución normal y con varianzas no homogéneas: Se observó la superposición de cinturas de los boxplots (Fig. 4.8).
- d) Sin distribución normal y con varianzas homogéneas: Se emplearon la prueba de Kruskal-Wallis y la prueba de Tukey para variables sin distribución normal (Fig. 4.8).

Para aquellos casos en los que las diferencias entre medias se evalúan mediante la prueba de Tukey para variables con distribución normal, en los resultados se incluyen los p - valor

de la prueba para cada par de medias. Por el contrario, para aquellos en que se emplea la prueba de Tukey para variables sin distribución normal se incluye la salida del software R para cada par de clases, donde *TRUE* significa que la diferencia de medias entre las dos clases es significativa, mientras que *FALSE* significa que no lo es.

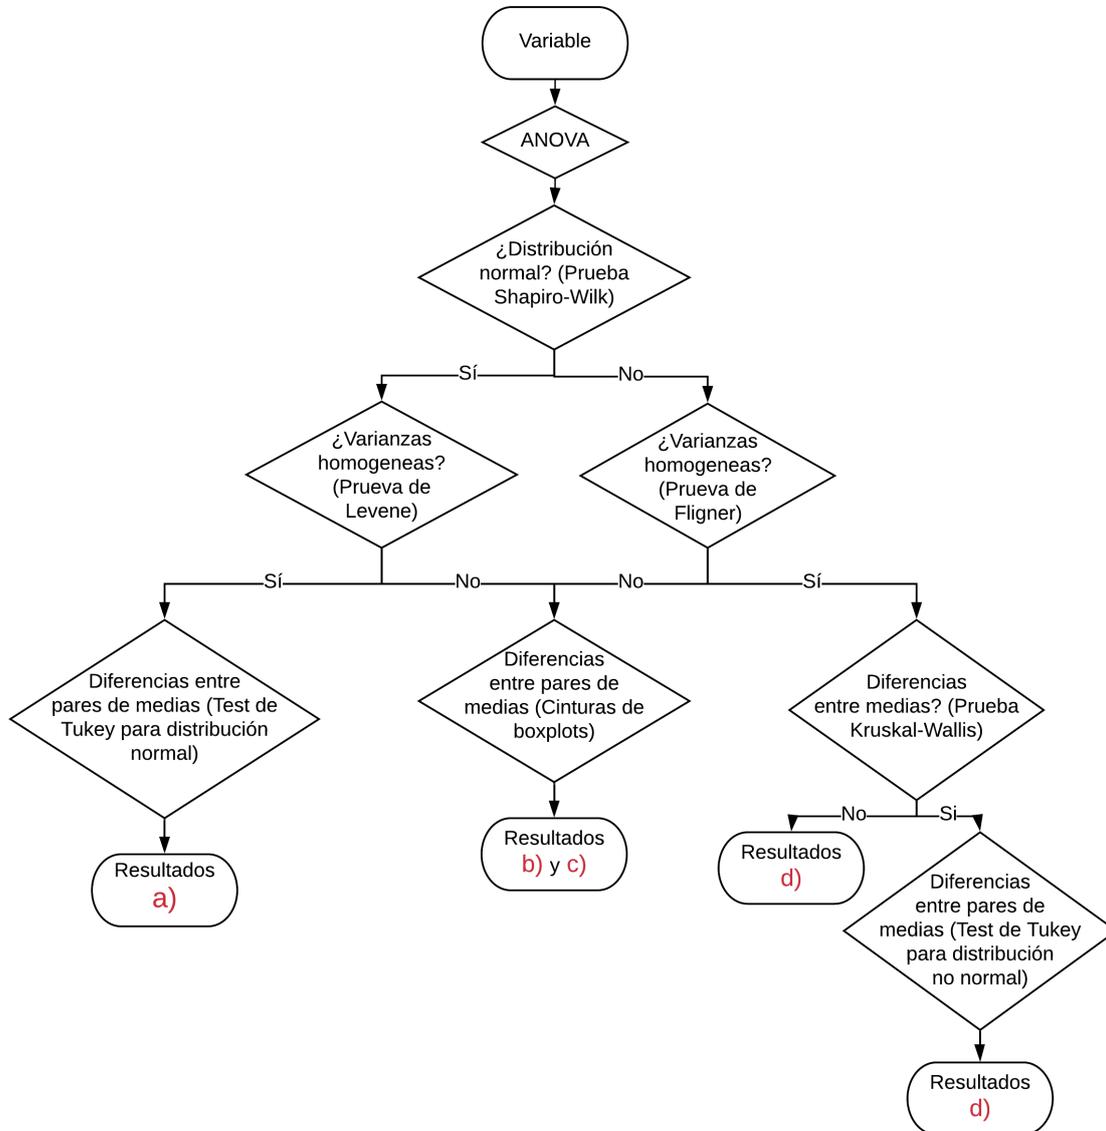


Figura 4.8: Pruebas de hipótesis de diferencias de medias

4.4. Separabilidad de clases

4.4.1. Análisis marginal

Para todas las series temporales se calcularon la media y desvío estándar anual de la serie temporal de cada clase y se graficaron en boxplots.

Para evaluar si las diferencias entre medias y desvíos estándar anuales observadas en los gráficos de cajas y bigotes eran estadísticamente significativas se sometieron a la prueba de igualdad de medias ANOVA con las 3 clases como tratamiento.

Posteriormente, se evaluaron los supuestos del ANOVA sobre los residuos resultantes. Como los datos no cumplen con los supuestos de normalidad se sometieron a una prueba de diferencia de medias no paramétrica. La prueba utilizada fue la de Kruskal-Wallis. El supuesto de homogeneidad de la varianza se probó también con una prueba no paramétrica, la de Flingner-Killeen. Como los datos no cumplen con el supuesto de homogeneidad de varianzas para el test de Kruskal-Wallis, las conclusiones sobre diferencias de medias se desprendieron de los gráficos de cajas y bigotes, basados en Krzywinski & Altman [41] y en Chambers et. al [42].

Todas las pruebas se realizaron con el software estadístico R.

4.4.2. Análisis de estructura temporal

Para cada variable se creó la serie temporal media de cada clase, promediando para cada fecha los valores de todos los puntos de verdad de campo de la clase en cuestión. Luego se analizó para cada variable la semejanza entre los pares de series temporales medias (*lluc-mix*, *nat-mix*, *nat-lluc*) mediante 3 medidas de distancias vectoriales descritas en 2.5.2: la distancia de Bray Curtis, el coeficiente de correlación temporal [47] y el coeficiente de disimilitud D [47]. Este último se calculó según la Ec. 4.3:

$$D(U, V) = f(cort(U, V)) \cdot DBC(U, V) \quad (4.3)$$

Donde $D(U, V)$ es el coeficiente de Disimilitud, $DBC(U, V)$ la distancia de Bray Curtis y $cort$ el coeficiente de correlación temporal entre los vectores U y V .

El cálculo fue realizado en Python 3.6.7. Para el cálculo de la distancia Bray Curtis se empleó la función `scipy.spatial.distance.braycurtis` de la librería Scipy [48].

4.5. Clasificaciones

Se realizaron clasificaciones basadas en píxeles con 4 algoritmos de clasificación: Árboles de decisión (AD), Random Forest (RF), Support Vector Machine (SVM) y Análisis discriminante lineal (ADL).

Fueron clasificados los píxeles dentro de las áreas clasificadas como “bosque abierto” o “bosque denso” por Karlin et al. (2014) [22]. El resto de los píxeles, fueron enmascarados.

Como imágenes de entrada, se utilizaron las series temporales descritas en 4.2.1.1, 4.2.1.2 y 4.2.2: de Coeficiente de retrodispersión en VH y VV, Coherencia interferométrica en VH y VV, NDVI, Reflectancia medida por el sensor Sentinel-2 en las bandas 2,3,4,5,6,7,8,8A,11 y 12.

Todas las clasificaciones fueron evaluadas mediante la creación de su Matriz de confusión, el cálculo de la Precisión global (PG), índice Kappa (K) y los errores de comisión (EC) y de omisión (EO) de cada clase. El mismo conjunto de datos de validación fue utilizado para todas las evaluaciones. Fue creado mediante la selección aleatoria del 40% (87) de píxeles del conjunto de datos de campo. Esta selección contiene la misma proporción de píxeles de cada clase, y fue realizada con el programa `landcover_classification` de Harald Kristen (2017) [69].

Los procedimientos se detallan a continuación:

4.5.1. Árboles de decisión

Las clasificaciones se realizaron según el diagrama de flujo de la Fig. 4.9 y las Ec. 4.4 y 4.5. Para este procedimiento se creó un programa en Python 3.6.7.

Como variables, se usaron la media y el desvío estándar para cada clase, de cada serie temporal. Los umbrales (th) fueron seleccionados al azar.

Primero, se calculó con la Ec. 4.4 para cada píxel su peso individual para cada clase y cada variable ($W_{n,m}$) en base a la pertenencia al rango intercuartílico de esa clase en esa variable. Luego, para calcular el peso total de cada píxel en cada clase (W_{T_m}), se sumaron para cada píxel los pesos individuales correspondientes a todas las variables para cada clase, según la Ec. 4.5.

$$W_{n,m}(i) = \begin{cases} 1/N & \text{si } i \in IQR_{n,m} \\ 0 & \text{si } i \notin IQR_{n,m} \end{cases} \quad (4.4)$$

Donde $W_{n,m}(i)$ es el peso del píxel i , para la variable n y la clase m ; N es el total de variables; $IQR_{n,m}$ es el rango intercuartílico para la clase m en la variable n .

$$W_{T_m}(i) = \sum_{n=1}^N W_{n,m}(i) \quad (4.5)$$

Donde $W_{T_m}(i)$ es el peso total del píxel i para la clase m , para todas las variables, N es el número de variables y $W_{n,m}(i)$ es el peso para el píxel i en la variable n y la clase m .

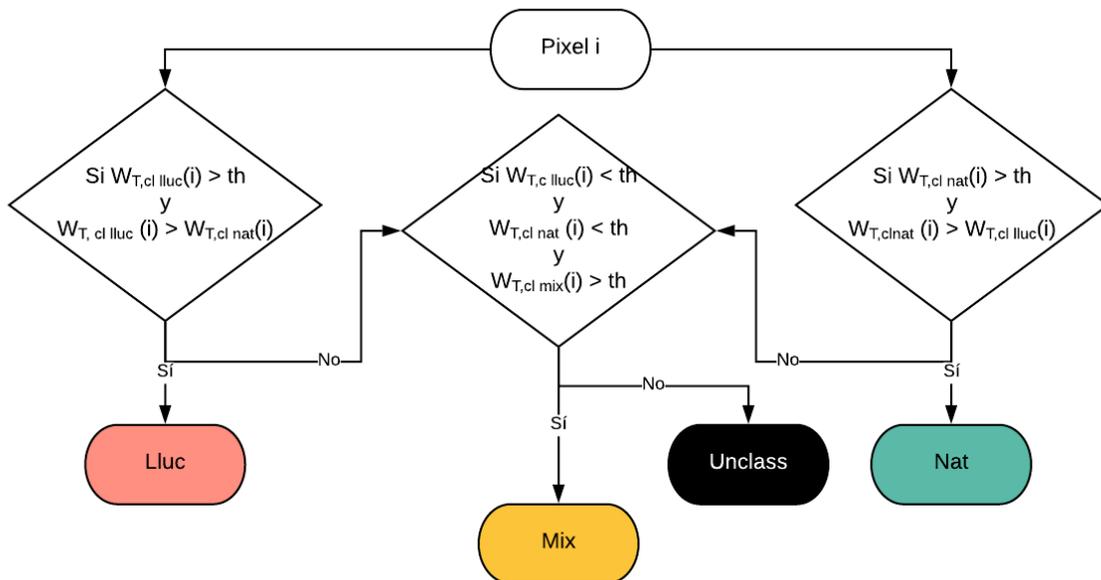


Figura 4.9: Diagrama de flujo de clasificador de árbol de decisión
th: umbral

En las Figuras 5.4 y 5.5 de la Sección 5.2.1 se encuentran los boxplots de las medias y desvíos estándar anuales por clase para todas las variables.

Los píxeles clasificados como *lluc* fueron aquellos cuyos valores se encontraron dentro del rango intercuartílico de las variables para la clase *lluc*, en al menos el $(th \cdot 100)\%$ de las variables; y en más variables que para la clase *nat*. En otras palabras, fueron etiquetados

como *lluc* cuando su W_T para la clase *lluc* fue mayor que el umbral (th) y mayor que para la clase *nat*.

Análogamente, los píxeles clasificados como *nat* fueron aquellos cuyos valores se encontraron dentro del rango intercuartílico de las variables para la clase *nat*, en al menos el $(th*100)\%$ de las variables; y en más variables que para la clase *lluc*. Es decir, que fueron etiquetados como *nat* cuando su W_T para la clase *nat* era mayor que el umbral (th) y mayor que para la clase *lluc*.

Por otra parte, fueron clasificados como *mix* aquellos píxeles que pertenecieron al rango intercuartílico de la clase *mix* en al menos el $(th*100)\%$ de las variables, y en menos del $(th*100)\%$ para las clases *nat* y *lluc*. Es decir, fueron etiquetados como *mix* los píxeles con W_T para las clases *nat* y *lluc* menor al umbral (th) y para la clase *mix* mayor a este umbral (th).

Los píxeles que no cumplieron con las condiciones para ser etiquetados como *nat*, *lluc* o *mix* no fueron clasificados y son identificados como “unclassified”.

Se realizaron 5 clasificaciones con diferentes combinaciones de variables y umbrales, como se detalla en la tabla 4.5. Las tres primeras clasificaciones (DT1, DT2 y DT3) toman como variables a las medias y los desvíos estándar de todas las series temporales. Luego, con el objetivo de disminuir el volumen de datos incluidos en la clasificación, se seleccionaron sólo las medias y desvíos estándar en las que se observaban mayores diferencias entre las clases (en los boxplots de las Fig. 5.4 y 5.5 de la sección 5.2.1) y se construyeron los árboles de decisión DT4 y DT5, con el umbral=0.3.

Tabla 4.5: Combinaciones de variables y umbrales en árbol de decisión

	Variables	Umbral
DT1	Media y desvío estándar de coh VH, coh VV, CR(dB) VH, CR(dB) VV, NDVI, B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	0.3
DT2	Media y desvío estándar de coh VH, coh VV, CR(dB) VH, CR(dB) VV, NDVI, B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	0.4
DT3	Media y desvío estándar de of coh VH, coh VV, CR(dB) VH, CR(dB) VV, NDVI, B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12	0.5
DT4	Media de B8A,B7,B5,CR(dB) VV,coh VH,coh VV,NDVI y B2	0.3
DT5	Media de NDVI y B5 y Desvío estándar de B2 y coh VV	0.3

4.5.2. Random Forest, Support Vector Machine y Análisis discriminante lineal

Se realizaron 11 clasificaciones con cada clasificador. La Tabla 4.6 muestra las variables de entrada, que son series temporales o combinaciones de ellas. Todas las clasificaciones fueron realizadas mediante funciones de Python 3.6.7.

Alrededor del 60 % (137 píxeles) del total de 224 píxeles de datos de campo fueron utilizados como datos de entrenamiento, mientras que el 40 % restante (87 píxeles), ya mencionado en 4.5, fueron utilizados para la validación. El mismo conjunto de datos de entrenamiento fue utilizado para todas las clasificaciones. Fue creado, al igual que el conjunto de datos de validación, mediante el programa *landcover_classification* de Harald Kristen (2017) [69] y contiene la misma proporción de píxeles de cada clase.

Tabla 4.6: Series temporales de entrada

Serie temporal de entrada
coh VH
coh VV
CR(dB) VH
CR(dB) VV
NDVI
NDVI + coh VH
NDVI + coh VV
NDVI + CR(dB) VH
NDVI + CR(dB) VV
NDVI + B2 + coh VH
coh VH + CR(dB) VH

Para las clasificaciones realizadas con los clasificadores RF y SVM se utilizó el programa *landcover_classification* creado por Harald Kristen [69]. Este programa, emplea las funciones *RandomForestClassifier* [70] y *SVC* [71] de la librería *sklearn* [72] de Python. Para la optimización de los parámetros de diseño de los clasificadores utiliza una función llamada *GridSearchCV*[73] de la misma librería de Python (*sklearn* [72]), que encuentra la mejor combinación de parámetros dado un set de datos de entrada.

Las clasificaciones con el método de Análisis discriminante lineal fueron realizadas con la función *LinearDiscriminantAnalysis* de la librería *Scikit-learn* [72] de Python.

4.6. Interpretación geográfica de las clasificaciones

Fueron seleccionadas las mejores imágenes clasificadas obtenidas con cada clasificador en función de las medidas de precisión y de la interpretación visual de los resultados. Las imágenes seleccionadas se detallan en la Tabla 4.7)

Tabla 4.7: Imágenes seleccionadas

Clasificador	Serie temporal de entrada
RF	Coh VV + NDVI
ADL	Coh VH + NDVI
DT1	media y desvío estándar de Coh VH, Coh VV, CR VH, CR VV, NDVI, B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12

Se graficaron los histogramas particionados por clases de los píxeles dentro de las clases de bosque de Karlin et. al[22].

Para cada imagen seleccionada se calcularon las distancias entre píxeles de cada clase y las vías de escurrimiento o centros urbanos, debido a que autores como Gavier et al. [9], Hoyos et al. [4] y Salazar et al. [20] informaron que éstos son factores asociados a la presencia de *L. lucidum*. Por otra parte, también se calculó la pendiente del terreno en áreas cubiertas por las clases ya que en campañas de campo se observó que la abundancia de *L. lucidum* está

relacionada con valores de pendiente elevados. Los procedimientos involucrados se detallan a continuación.

Se calcularon:

- a) La proporción de píxeles de cada clase a menos o más de 100 m de las vías de escurrimiento. Este umbral fue seleccionado para evaluar la disponibilidad de agua y el transporte de semillas por cursos de agua como factores influyentes en la expansión de la especie invasora *L. lucidum*. El archivo vectorial de las vías de escurrimiento fue obtenido del Modelo Digital de Elevación de SRTM.
- b) La proporción de píxeles de cada clase a menos o más de 600 m de áreas urbanas. Este umbral fue elegido en base a Gavier et al. [9]. El archivo vectorial de áreas urbanas fue creado a partir de los archivos de la red vial y los centros urbanos de Argentina del IGN (Instituto Geográfico Nacional), disponibles en [74]. Los centros urbanos que se incluyeron en el análisis fueron las ciudades de Carlos Paz, Córdoba y La Calera; mientras que los caminos de la Red Vial fueron las Rutas Nacional n° 20, Provincial n° 73, Provincial E64, Nacional n° 38 y el camino interno de la RNDLC que la recorre en sentido N-S, entre las rutas Provincial E64 y Nacional n° 38.
- c) La proporción de píxeles de cada clase sobre sitios con pendiente menor o mayor a 25%. Los valores de pendiente fueron obtenidos del Modelo Digital de Elevación Alos Palsar con resolución espacial de 12.5 m.

4.7. Re-validación de resultados

Con la misma metodología detallada en la sección 4.1 se tomaron nuevas muestras de campo. Con el objetivo de evaluar la robustez de las metodologías en nuevos sitios con las mismas características florísticas, edáficas y climáticas se evaluó la proporción de estos sitios de muestreo correctamente clasificados en las imágenes de la Tabla 4.7. Las fechas de muestreo fueron 31/10/2019 y 10/09/2020.

Resultados y discusión

5.1. Análisis descriptivo de series temporales

5.1.1. Coherencia interferométrica

La coherencia interferométrica en banda C parece estar relacionada con el crecimiento de los bosques. En esta banda, se obtiene información de las hojas del dosel, ya que la señal no penetra en la canopia. Cuando la vegetación crece, la coherencia disminuye debido a que por la aparición de nuevas hojas y ramas pequeñas cambian las características dispersoras del medio entre una imagen y la siguiente [11]. En ausencia de cambios bruscos en la cobertura boscosa (como tala o caída de árboles) que arrojarían valores de coherencia cercanos a 0, valores de coherencia bajos (pero no cero) denotan crecimiento en tanto que valores más altos denotan menores cambios, es decir, menor tasa de crecimiento (Ver Anexo A).

Las especies nativas mostraron valores de coherencia medios anuales mayores en ambas polarizaciones durante todo el año. Esto podría indicar que *L. lucidum* tiene mayor tasa de crecimiento que las especies nativas, acordando con Zeballos et. al [1].

En el único momento en que se observa que la coherencia de la especie *L. lucidum* supera a las nativas es después de periodos de alta precipitación. Durante el mes de Mayo (Fig. 5.1a y 5.1b) (0705_1905) la especie *L. lucidum* muestra valores mayores que las especies nativas en ambas polarizaciones, aunque esta diferencia no es significativa (ver Tablas C.1 y C.2, Anexo C)

La coherencia más alta para la clase *nat* que para *lluc* en ambas polarizaciones en el comienzo del mes de Enero (Fig. 5.1) podría deberse a que en este momento las especies nativas presentan crecimiento acotado de hojas y ramas ya que están destinando la mayor parte de sus fotoasimilados a la producción de frutos [23]. Esta diferencia parece ser significativa para la fecha 07/01-19/01 ya que no se observó superposición de las cinturas de los boxplots de las clases *nat* y *lluc* en ambas polarizaciones (Tablas C.1 y C.2, Anexo C).

Durante los meses de Febrero, Marzo y Abril (Fig. 5.1), ambos grupos muestran valores de coherencia bajos, en algunos casos con diferencias significativas entre ellos (Tablas C.1 y

C.2, Anexo C). Esto podría denotar crecimiento activo de la vegetación.

Durante la estación seca (de Mayo a Septiembre) (Fig. 5.1), todas las clases muestran un incremento en los valores de coherencia en ambas polarizaciones, lo cual sugiere que disminuyen su crecimiento debido a la ocurrencia de periodos de bajas temperaturas y precipitaciones.

Sin embargo, en Junio la coherencia en polarización VH de la clase *nat* es estadísticamente menor que la de *lluc* (Fig. 5.1a 31/05-12/06, Tabla C.1), denotando una mayor tasa de crecimiento de la primer clase. Mientras tanto, en polarización VV (Fig. 5.1b) el comportamiento es inverso (Diferencia significativa, Tabla C.2, Anexo C). Esto podría explicarse por lo siguiente: en la polarización VV al disminuir el contenido hídrico de las hojas de las nativas éstas se vuelven más transparentes a la onda de radar, que empieza a tomar información de los troncos, mucho más estables en el tiempo que las hojas, por lo que la coherencia es mayor. Para la clase *lluc*, en cambio, las hojas continúan con niveles de humedad tales que siguen siendo percibidas por la onda de radar de banda C, por lo que los niveles de coherencia entre una imagen y la siguiente se mantienen más bajos. En la polarización VH, por el contrario, este comportamiento no se observa ya que es más sensible al mecanismo de retrodispersión en volumen.

En Junio se observa la mayor variación para todas las clases. Se puede deber a la presencia de especies caducifolias (como *Morus alba* L. o *Melia azedarach* L.) dentro de las áreas estudiadas. Las caducifolias, en este momento en que se encuentran sin hojas, presentan mayores valores de coherencia que las perennifolias, lo que se convierte en una gran fuente de variación de los valores de coherencia en píxeles que no son totalmente homogéneos.

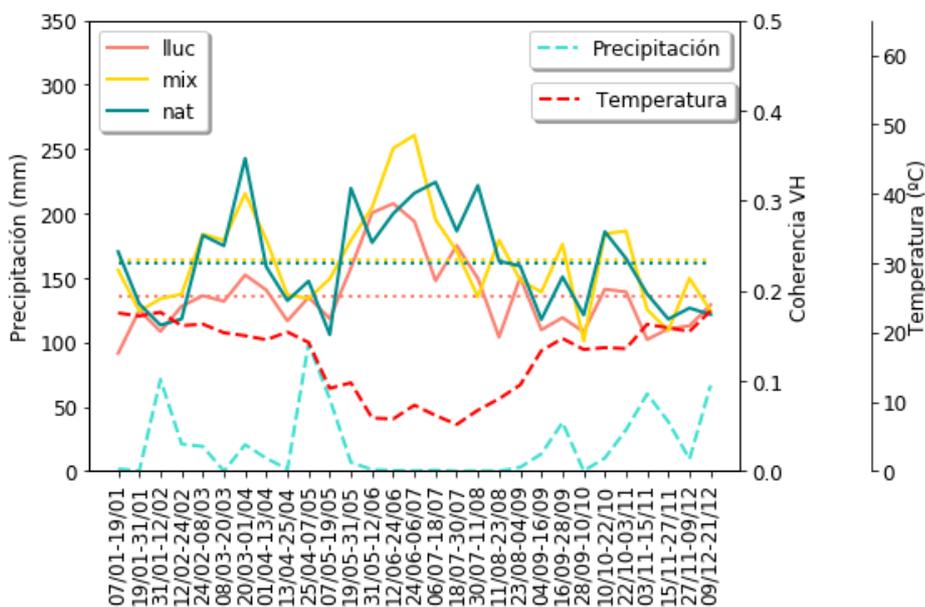
Durante Julio y Agosto (Fig. 5.1) los valores de coherencia de las especies nativas son estadísticamente mayores a los de *L. lucidum* (excepto 1807_3007 polarización VH y 1108_2308 polarización VV, Tablas C.1 y C.2, Anexo C). Esto sugiere que las especies nativas detienen su crecimiento en los meses de la estación seca, mientras que *L. lucidum* continua con el crecimiento y fructificación y con ello, con el consumo de agua. Estos resultados se condicen con Diez et. al [5] y Catford et. al [6] que proponen que el reemplazo de vegetación arborea nativa por especies invasoras en la porción superior de las cuencas incrementa la ocurrencia de períodos de sequía en cuencas de montaña.

Desde Septiembre a Diciembre (Fig. 5.1) los valores de Coh son menores que en los meses invernales precedentes. El inicio de este periodo coincide con el inicio de la estación de crecimiento. Los valores mínimos se observan en Noviembre, lo que debería coincidir con la tasa máxima de crecimiento de las especies presentes en las clases.

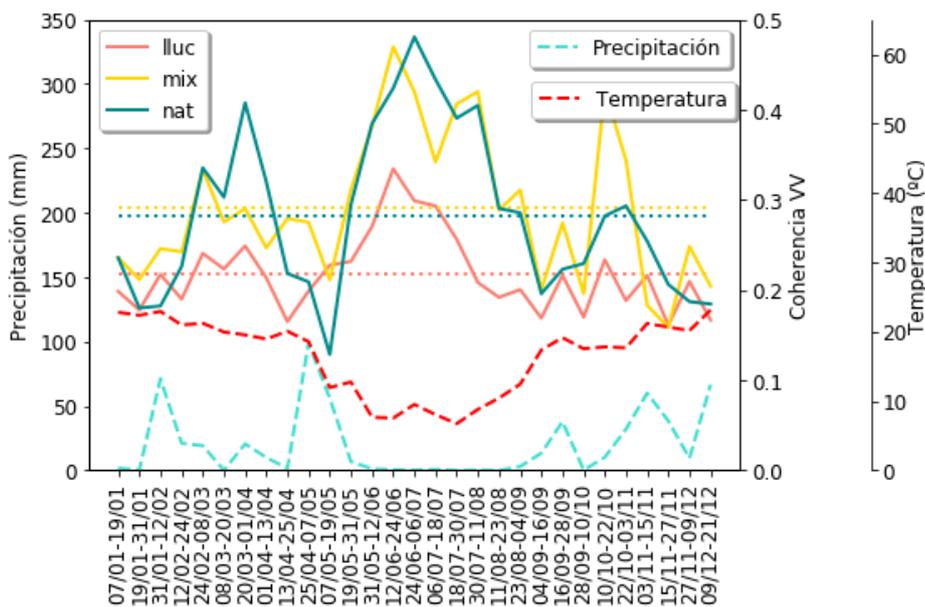
En líneas generales, el comportamiento de los píxeles mixtos parece asemejarse más al de los de especies nativas que a los de *Ligustrum lucidum*. Esto coincide con lo observado por [9]: individuos de *L. lucidum* se encuentran formando bosques, pero también como individuos aislados dentro de parches de bosque nativo. Es en éstas áreas donde el sensado remoto tiene limitaciones para detectarlo y los mapas producidos por estas técnicas resultan en subestimaciones de área invadida por esta especie exótica invasora. Debe considerarse el análisis de imágenes SAR como de COSMO-SkyMed que aunque tienen mayor resolución temporal (16 días), su mejor resolución espacial podría permitir la diferenciación en estas áreas mixtas. Sin embargo, debe analizarse también si el aumento de 4 días en la línea de base temporal (de 12 a 16 días) y la disminución en la longitud de onda (Banda C en Sentinel-1 y banda X en COSMO-SkyMed) no generan la completa pérdida de coherencia en la vegetación.

Debido a que las imágenes SAR no son afectadas por nubosidad, puede complementar los análisis clásicos con imágenes ópticas que usan índices verdes. Otra ventaja es la periodi-

cidad (12 días) de las imágenes gratuitas de Sentinel-1. Si el objetivo es la diferenciación de tipos de bosques, debería considerarse también el uso de imágenes de sensores en banda L (como SAOCOM) que por su longitud de onda puede penetrar más profundamente en la canopia y aportar información extra a este análisis de diferenciación.



(a) Coherencia VH



(b) Coherencia VV

Figura 5.1: Series temporales de Coherencia interferométrica.

Líneas continuas: series temporales medias de los puntos de los datos de campo para cada clase. Líneas punteadas: valores medios de esas series. Líneas cortadas rojas y celestes: valores medios de temperatura y acumulados de precipitaciones, respectivamente, para los intervalos de tiempo.

5.1.2. Coeficiente de Retrodispersión en dB

La Figura 5.2 muestra que las series temporales de CR, en polarización VH o en VV, con un intervalo entre imágenes de 12 días parecen seguir el comportamiento de la precipitación. Esto comprueba la existencia de sensibilidad del sensor SAR al contenido de humedad. A mayor contenido de humedad, aumenta la constante dieléctrica y con ello el coeficiente de retrodispersión.

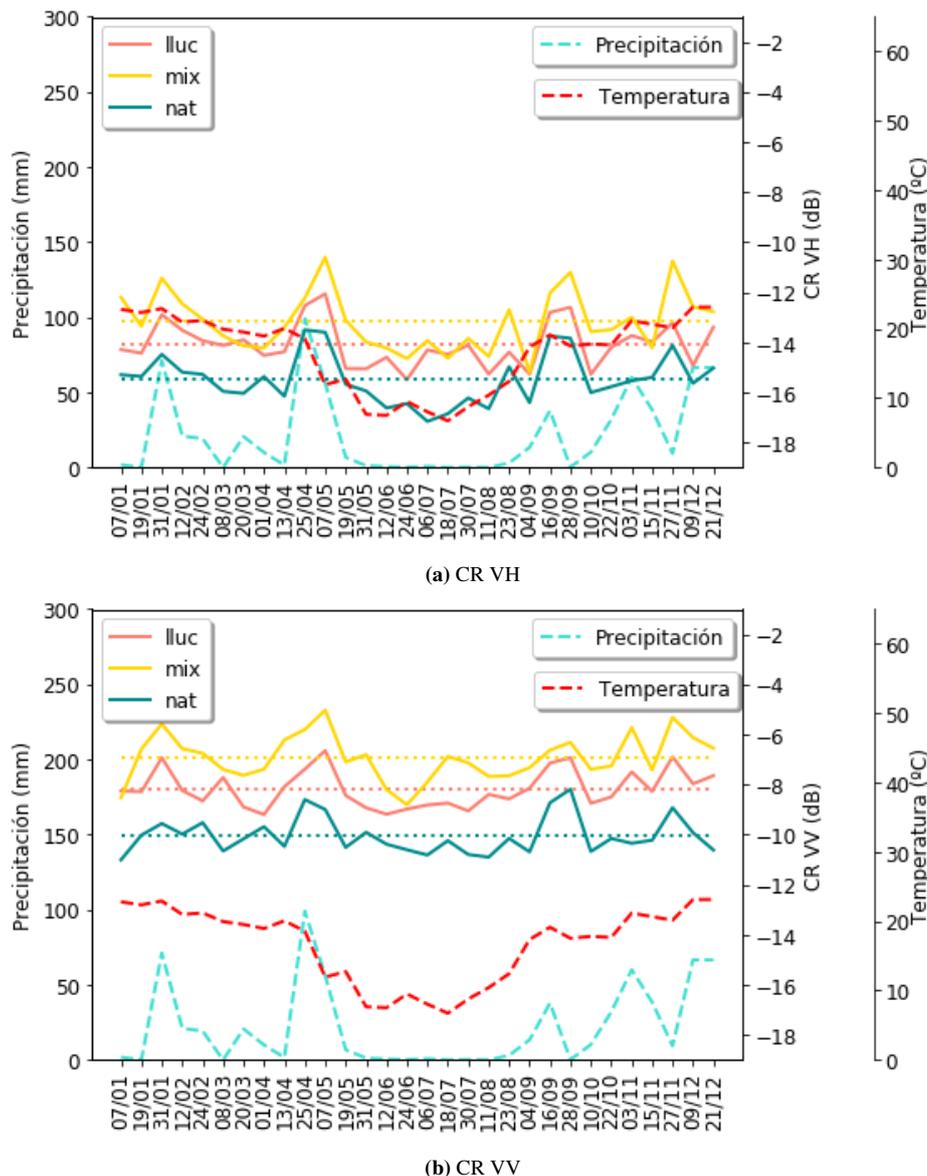


Figura 5.2: Series temporales de Coeficiente de retrodispersión.

Líneas continuas: series temporales medias de los puntos de los datos de campo para cada clase. Líneas punteadas: valores medios de esas series. Líneas cortadas rojas y celestes: valores medios de temperatura y acumulados de precipitaciones, respectivamente, para los intervalos de tiempo.

En la polarización VV (Fig. 5.2b) los valores observados son mayores a los de la polarización VH (Fig. 5.2a). Esto se debe a que, como se mencionó en la sección 2.4, en la polarización VV la señal es más sensible a la retrodispersión en superficie, mientras que en VH a la retrodispersión en volumen. Con este último mecanismo de retrodispersión, la señal enviada interactúa más con el objetivo y regresa al sensor más atenuada que con el mecanismo de retrodispersión en superficie.

La clase *nat* presenta menores valores de coeficiente de retrodispersión que la clase *lluc*, en ambas polarizaciones, todo el año (el análisis estadístico de las diferencias se muestra en las tablas C.3 y C.2, en Anexo C). Esto puede deberse a la diferencia en la morfología y estructura de las especies presentes en las clases: las especies *L. molleoides* y *S. commersoniana* (presentes en la clase *nat*) tienen hojas más pequeñas que *L. lucidum* (presente en la clase *lluc*), y la corteza de sus ramas es rugosa. Esto hace que la señal enviada por el sensor interactúe más con las especies nativas y la respuesta que llega al sensor sea más débil.

Los momentos en que se observa mayor diferencia entre las clases *nat* y *lluc* coinciden con los periodos de mayor precipitación.

La clase *mix* no pareciera tener un comportamiento similar a ninguna de las otras clases, ni ser una mezcla aditiva entre ellas dado que su serie temporal media no toma valores medios entre las series de las otras dos clases.

5.1.3. NDVI

En la Figura 5.3 se observa que el NDVI se relaciona con los ciclos de temperatura y precipitación anuales del área de estudio donde el 80 % de la precipitación anual está concentrada en el periodo estival. Los mayores valores de NDVI se observan en otoño, primavera y verano y los menores en invierno. La clase *lluc* tiene todo el año mayor NDVI que la *nat*. Esto sugiere que el contenido de clorofila y la densidad de *L. lucidum* es mayor al de las nativas.

El momento en que más se diferencian las clases de *L. lucidum* y de nativas es en el período invernal (aproximadamente de Julio a Octubre, con diferencias significativas en Tabla C.5, Anexo C). Si bien todas las especies son perennifolias, en esta época del año las hojas de los individuos de *S. commersoniana* se tornan de color rojizo sugiriendo una menor concentración de clorofila, por lo que es esperable que los valores de NDVI bajen más para esta especie.

Excepto los primeros tres meses del año (Enero y Febrero), la clase *mix* parece comportarse como una mezcla aditiva de las otras dos clases. Esto sucede porque la reflectancia en un pixel es la reflectancia promedio de los objetos presentes en la celda de resolución. En un caso ideal, si un pixel mixto está cubierto exclusivamente por vegetación de dos pixeles puros, es esperable que su reflectancia sea intermedia entre las reflectancias de los pixeles puros.

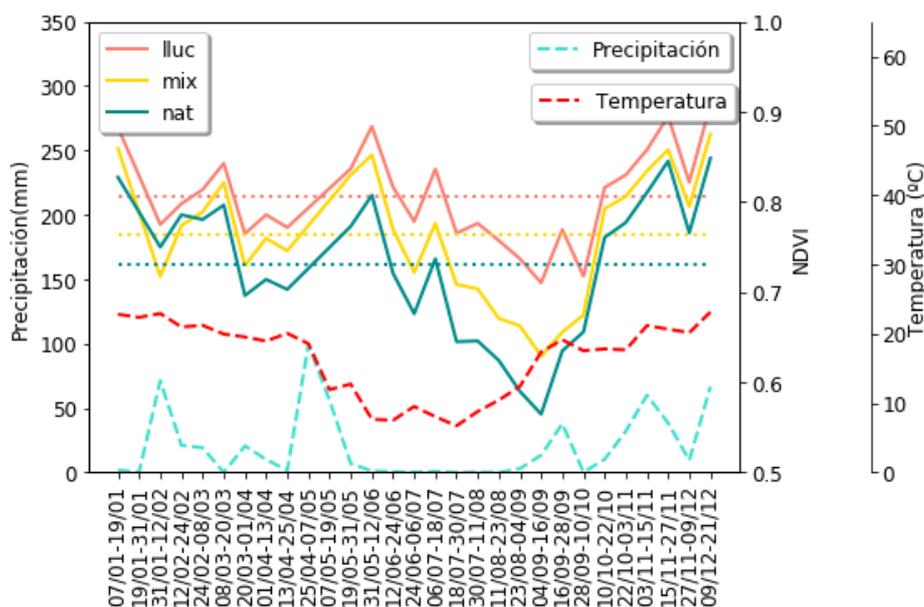


Figura 5.3: Serie temporal de NDVI.

Líneas continuas: serie temporal media de los puntos de los datos de campo para cada clase.

Líneas punteadas: valores medios de esas series.

Líneas cortadas rojas y celestes: valores medios de temperatura y acumulados de precipitaciones, respectivamente, para los intervalos de tiempo.

A modo de síntesis se incluyen en el Anexo 6 tablas con valores de desvío estándar, media, mínimo y máximo para cada clase y para cada variable: Bandas de reflectancia de MSI Sentinel 2 (B12,B11,B8A,B8,B7,B6,B5,B4,B3 y B2), Coh en las polarizaciones VH y VV, NDVI y CR en las polarizaciones VH y VV. Estas medidas resumen fueron calculadas para dos periodos: periodo seco (de Abril a Septiembre) y periodo húmedo (Enero-Marzo y Octubre-Diciembre).

5.2. Separabilidad de clases

5.2.1. Análisis marginal

Las Fig. 5.4 y Fig. 5.5 muestran los diagramas de caja y bigotes o *boxplots* para las medias y los desvíos estándares anuales de las series temporales para cada clase (*lluc*, *nat* y *mix*), respectivamente.

En cuanto a los valores de desvío estándar (Fig. 5.5), los de la clase *lluc* son menores que los de las otras clases en todas las bandas de reflectancia. Esto sugiere que la respuesta de la vegetación que cubre los sitios de esta clase fue más constante a lo largo del año.

Las medias de las series de reflectancia (Fig. 5.4) en la región del infrarrojo de onda corta-SWIR (B12 y B11) fueron mayores para la clase *nat* que para *lluc* y *mix*. El tamaño de las cajas indica que los datos presentan gran variabilidad, y esta es mayor para la clase *nat*.

En todas las series correspondientes a la región del infrarrojo cercano-NIR (B8A, B8, B7, B6 y B5) *lluc* presenta mayores valores medios que la clase *nat* y ésta a su vez mayor que *mix* (Fig. 5.4). Esta última clase es la más variable, y puede observarse también en la Fig. 5.4 en la que los valores anuales de desvío estándar para esta clase son mayores y más variables.

Con respecto a las series de reflectancia en la región del visible (B4, B3 y B2), la clase *nat* presenta los mayores valores y la mayor variabilidad.

Los valores medios de NDVI (Fig. 5.4) son mayores para la clase *lluc*. Al contrario de lo que se esperaba por ser la clase más heterogénea, la clase *mix* presenta la menor variabilidad entre sitios con respecto a las otras clases. Esto puede deberse a que la media anual no logra capturar la variabilidad del NDVI para esta clase, ya que mayor variabilidad se observó al analizar cada fecha de la serie temporal por separado (sección 2.2).

Las medias anuales de coeficiente de retrodispersión en ambas polarizaciones (CRVH y CRVV) son mayores para la clase *mix*. Se muestran muy variables y con medianas muy similares entre las clases *lluc* y *nat*. También son muy similares los desvíos estándares de estas clases (Fig. 5.5), lo que indica que la variación anual de estos valores a lo largo del año es similar entre las clases.

Las medias anuales de coherencia interferométrica (Coh VH y Coh VV) son las que mayores diferencias presentan entre las clases *lluc* y *nat*. La clase *mix* presenta los valores medios más variables, denotando heterogeneidad entre los puntos de verdad de campo. La clase *nat* toma valores de desvío estándar similares a *mix*, denotando similares variaciones a lo largo del año.

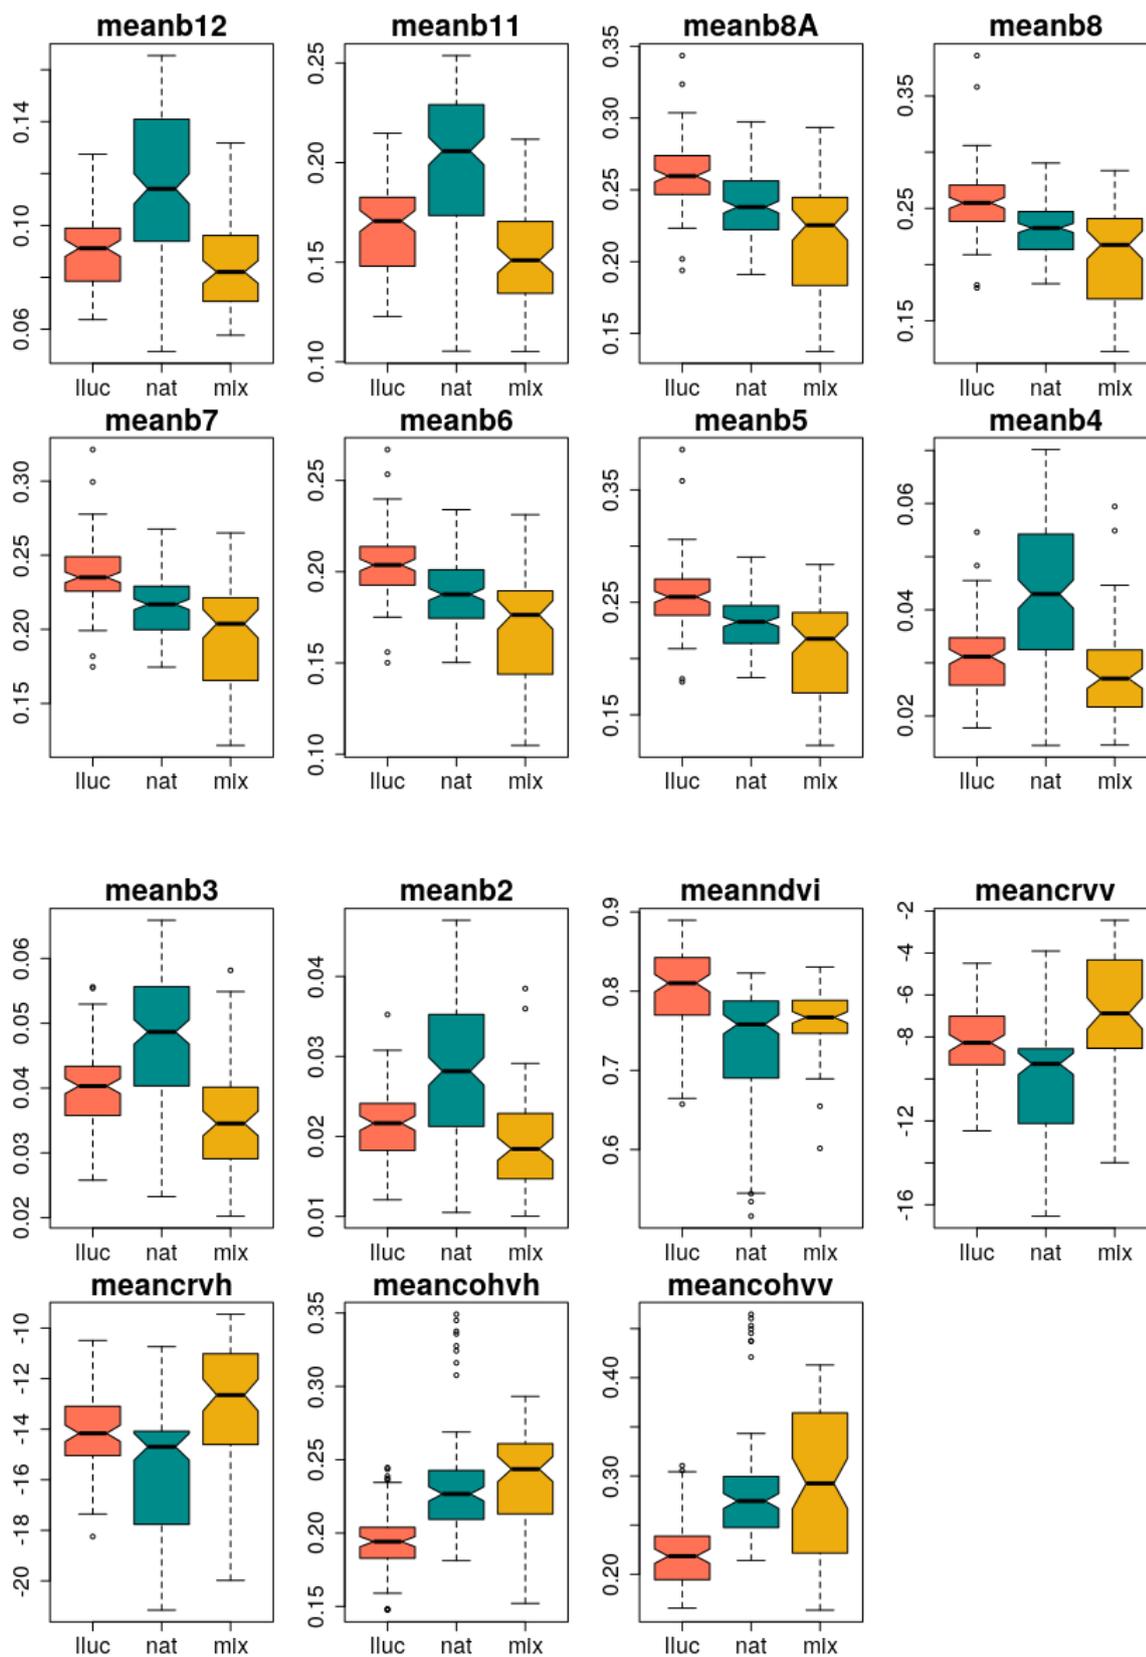


Figura 5.4: Boxplots para el estadístico *media* de las series temporales anuales por clases

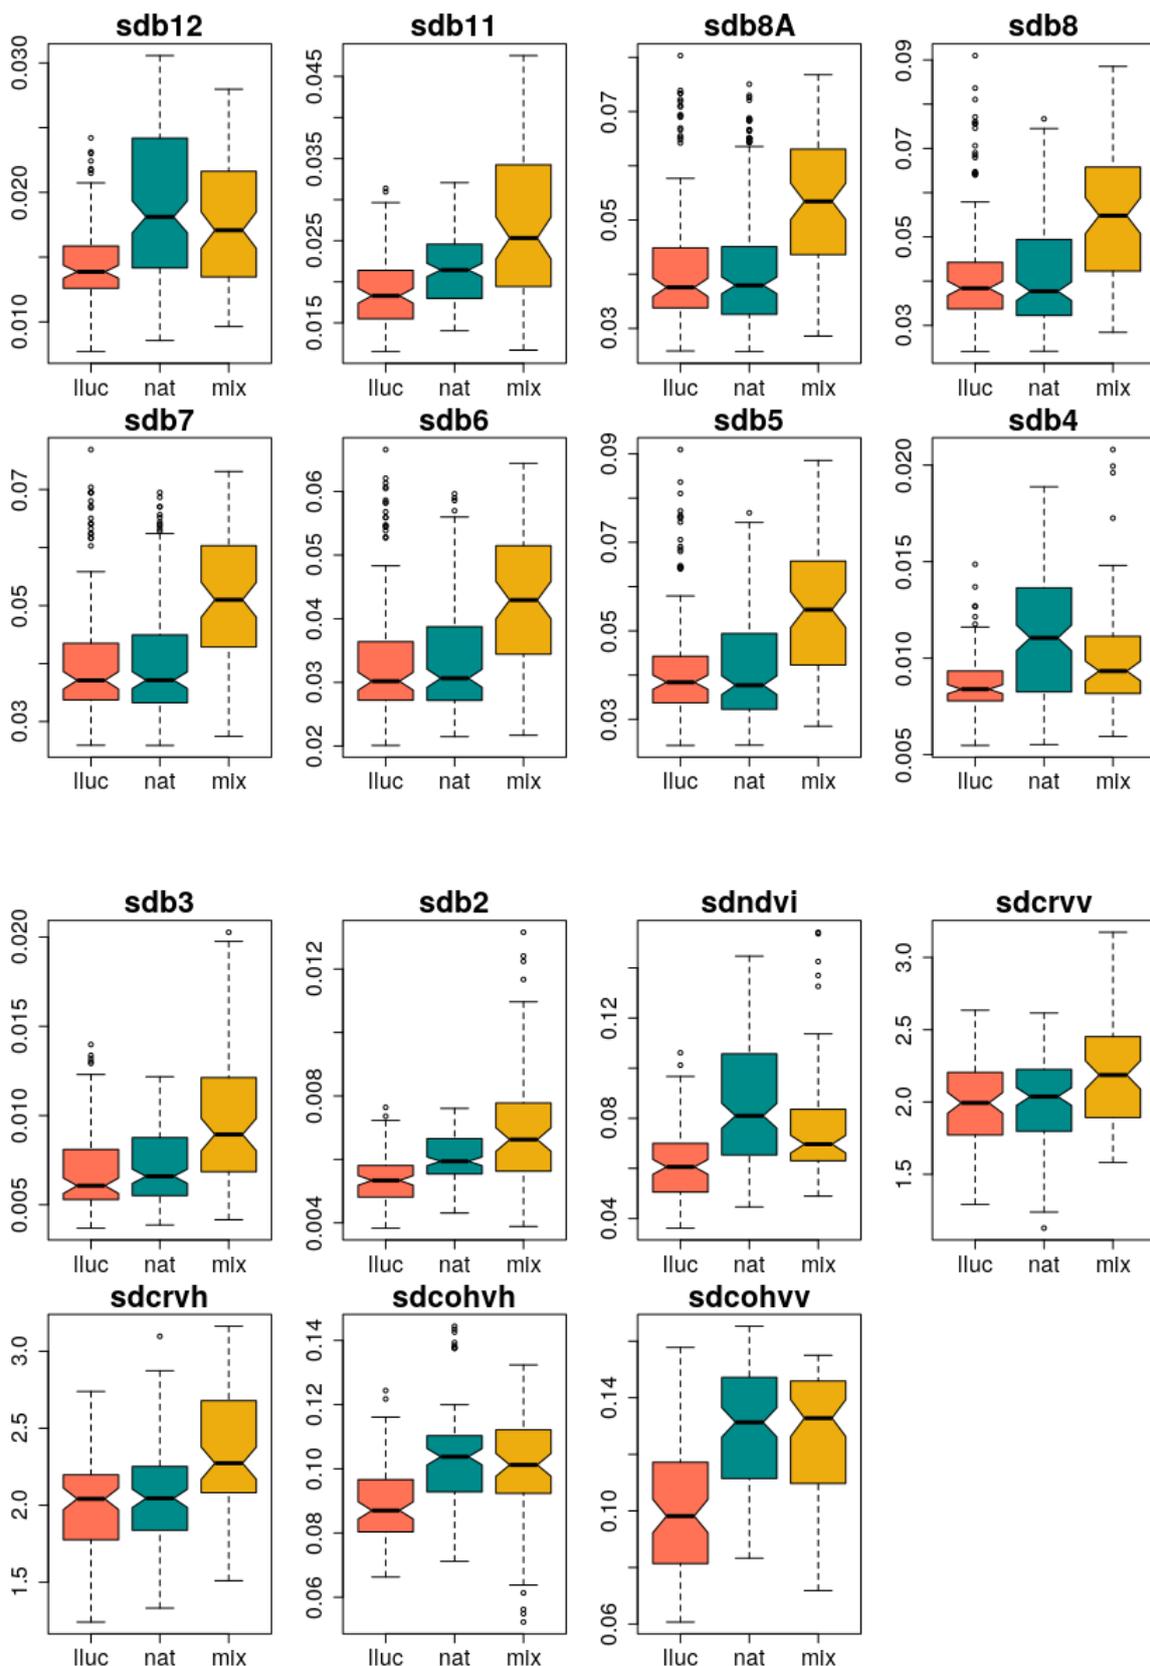


Figura 5.5: Boxplots para el estadístico *desvío estándar* de las series temporales anuales por clases

Se aplicó el test ANOVA con las clases como factor y luego el test de Shapiro-Wilks sobre los residuos estandarizados y se encontró que el conjunto de datos no cumple con el supuesto de normalidad. Es por ello que se debió emplear un test de comparación de medias adecuado para muestras sin distribución normal. Se aplicó el test de Kruskal-Wallis. El supuesto de

homogeneidad de varianzas de este test se probó con el test de Fligner-Killeen [46], que es apropiado para muestras sin distribución normal. Se encontró que para todas las variables las varianzas de los grupos no son homogéneas, motivo por el cual no se pudo sacar conclusiones de la prueba de Kruskal-Wallis.

La separabilidad de clases en función de la media y el desvío estándar anuales de las series se evaluó entonces por el solapamiento de los boxplots de cada clase, basados en Krzywinski & Altman [41] y en Chambers et. al [42], quienes afirman que si las cinturas de los boxplots no se solapan las diferencias son significativas; mientras que si se solapan no hay evidencias suficientes para concluir si las diferencias son o no significativas. Sin embargo, Chambers et. al [42] sugieren que esta interpretación visual del solapamiento de cinturas de boxplots no es adecuado cuando se cuenta con más de dos clases o factores.

No mostraron solapamiento de las cinturas los pares de boxplots:

- De las clases *lluc* y *nat*: todas las medias anuales (excepto para el CR VH), y los desvíos estándar anuales de las series de reflectancia en el infrarrojo de onda corta (B12 y B11), B4, B2, NDVI, Coh VH y Coh VV.
- De las clases *lluc* y *mix*: ninguna de las medias ni desvíos estándar anuales de las series temporales evaluadas.
- De las clases *nat* y *mix*: las medias anuales de las series de reflectancia en el infrarrojo de onda corta (B12 y B11) y en el visible (B4, B3 y B2), de CR VH, CR VV y Coh VH.

Por el contrario, los pares de boxplots que si mostraron solapamiento de las cinturas de boxplots fueron:

- De las clases *lluc* y *nat*: los de la media anual de CR VH y de los desvíos estándar de reflectancia en el infrarrojo cercano (B8A, B8, B7,B6 y B5) y en la B3, y de las series de CR VH y CR VV.
- De las clases *lluc* y *mix*: ninguna media ni desvío estándar.
- De las clases *nat* y *mix*: las medias anuales de reflectancia en el infrarrojo cercano (B8A, B8, B7,B6 y B5), NDVI y Coh VV, los desvíos estándar anuales de reflectancia en el infrarrojo de onda corta (B12 y B11) y de Coh VH y Coh VV.

5.2.2. Analisis de estructura temporal

A continuación se grafican en las Fig. 5.6, 5.7 y 5.8 los indicadores de separabilidad de clases Distancia de Bray Curtis, coeficiente de correlación temporal y coeficiente de disimilitud D con $k=1$ (definido en la Ec. 4.3) entre pares de clases por variable.

La Fig. 5.6 muestra los valores de distancia de Bray Curtis (*DBC*), que se basa en la cercanía entre los valores que toman las clases en una misma fecha. Mientras mayor sea esta distancia, más separables son las clases. La Fig. 5.6 entonces muestra que, según este indicador, las series temporales que mejor diferencian entre pares de clases dependen de las clases en cuestión:

- Las clases *nat* y *mix* se diferencian mejor con las series temporales de reflectancia en la región del visible (B2, B3 y B4) y con la de coeficiente de retrodispersión en VV.

- Las clases *lluc* y *mix* se diferencian mejor con la serie temporal de coherencia interferométrica en VV.
- Las clases *nat* y *lluc* se diferencian mejor con las series temporales de reflectancia en la región del rojo (B4) y coherencia interferométrica en VV.

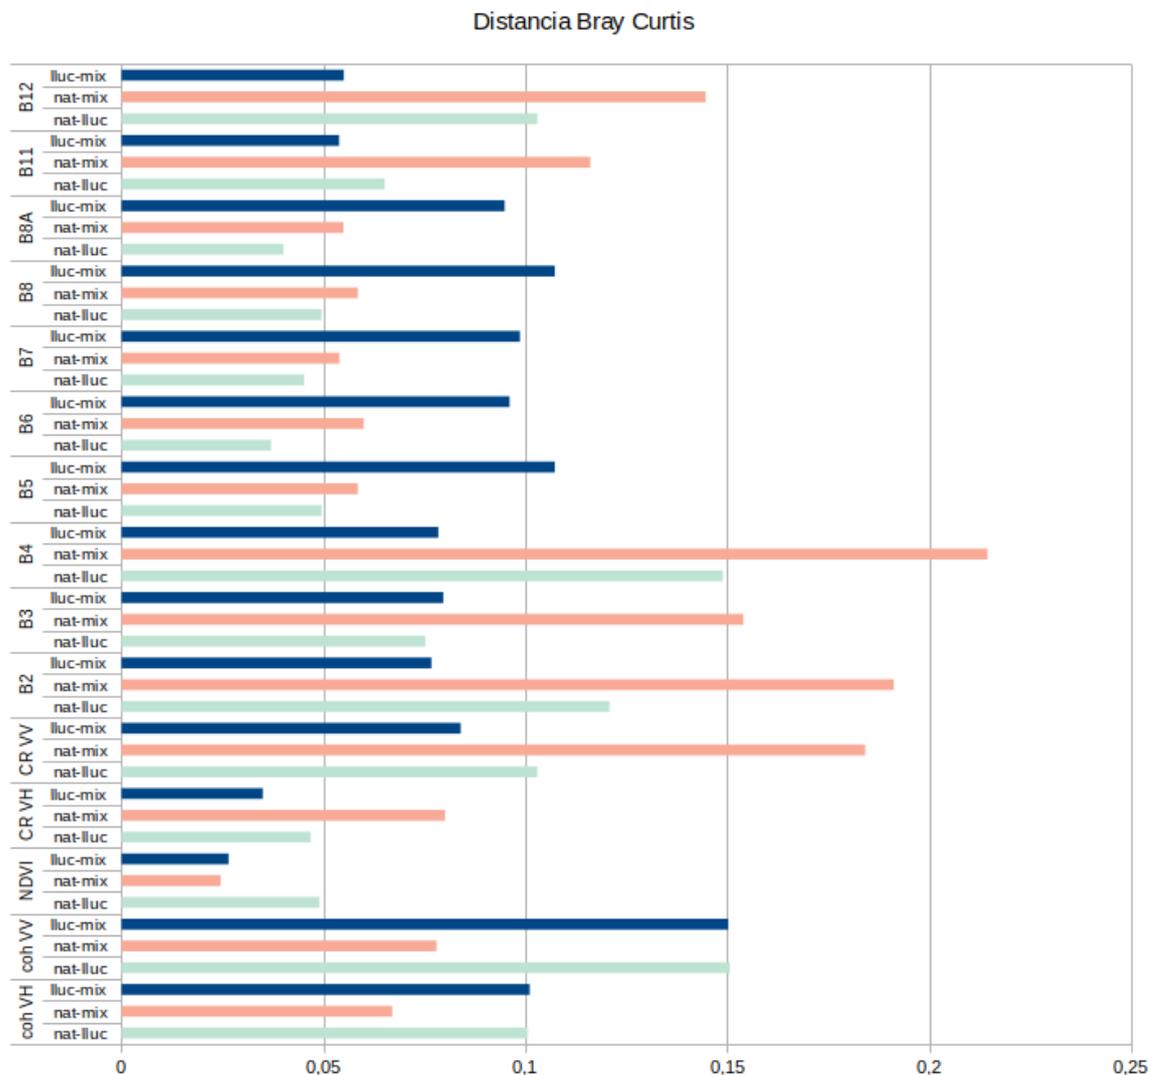


Figura 5.6: Distancia de Bray Curtis entre pares de clases por variable

Sin embargo, para ningún par de clases la Distancia de Bray Curtis supera el 0.25. Este valor de separabilidad de clases es bajo considerando que esta distancia oscila entre 0 y 1.

Por otra parte, el coeficiente de correlación temporal *cort* evalúa la similitud en las variaciones de la estructura temporal entre las series de las clases evaluadas. Mientras menor sea el valor de *cort* entre un par de clases, más diferenciables serán las mismas, según este indicador. La Fig. 5.7 muestra que las clases tienen un comportamiento muy similar entre pares para las series temporales provenientes del sensor S-2, es decir de reflectancias y NDVI, tomando valores cercanos 1. Por el contrario, para las series provenientes del SAR S-1 la estructura temporal es menos similar entre clases, siendo las series de Coherencia en ambas polarizaciones las que presentan menor similitud en la variación temporal entre clases.

Pueden entonces presentarse los siguientes casos:

- Que un par de clases sea difícil de diferenciar en cuanto a distancias entre elementos en una misma posición en el vector, pero más sencillo en función de las variaciones temporales; o el caso contrario.
- Que un par de clases sea diferenciable tanto por las distancias entre elementos en una misma posición como por las variaciones temporales de sus series.
- Que un par de clases no sea diferenciable por presentar series temporales muy cercanas y con comportamientos temporales muy similares.

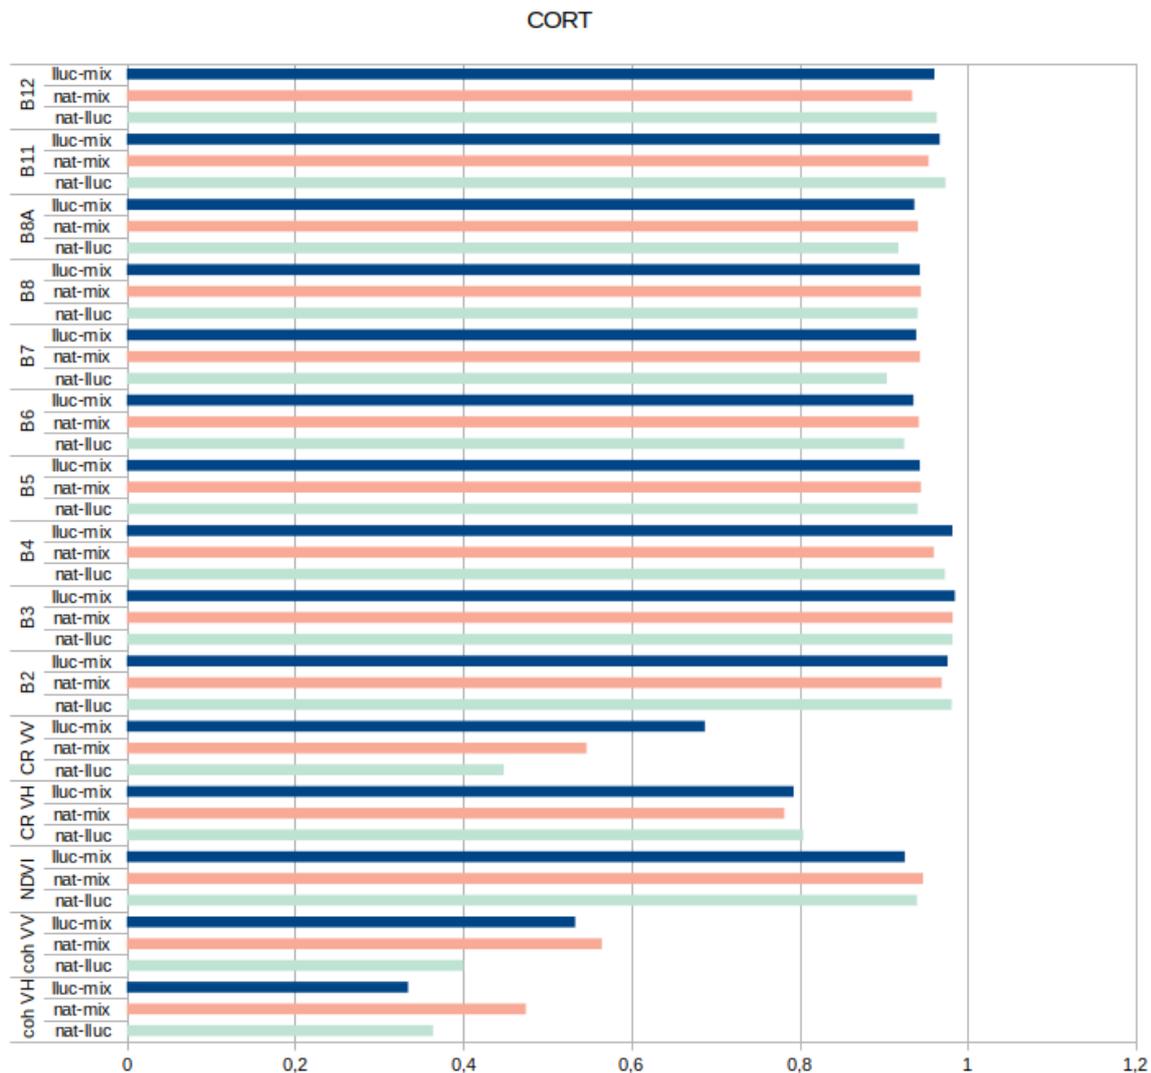


Figura 5.7: Coeficiente de correlación temporal entre pares de clases por variable

El coeficiente de disimilitud D calcula la disimilitud conjunta entre series de clases producida tanto por las distancias entre elementos en una misma posición en los vectores como por las variaciones temporales de las series. Con $k=1$, estos factores contribuyen a D en un 46,2% y 53,7% respectivamente. Según este indicador, mientras mayor sea el valor de D entre un par de clases, más diferenciables son las mismas.

Para los casos evaluados, la serie temporal que genera la mejor separabilidad de clases depende del par de clases que se comparen. Pero, en líneas generales y teniendo en cuenta los

tres pares de clases, la mayor separabilidad se obtiene con las series de coherencia interferométrica en sus dos polarizaciones (VH y VV), con el coeficiente de retrodispersión en polarización VV y con la reflectancia en el rojo (B4). Por el contrario, la menor separabilidad se obtiene con el coeficiente de retrodispersión en polarización VH y con el NDVI 5.8.

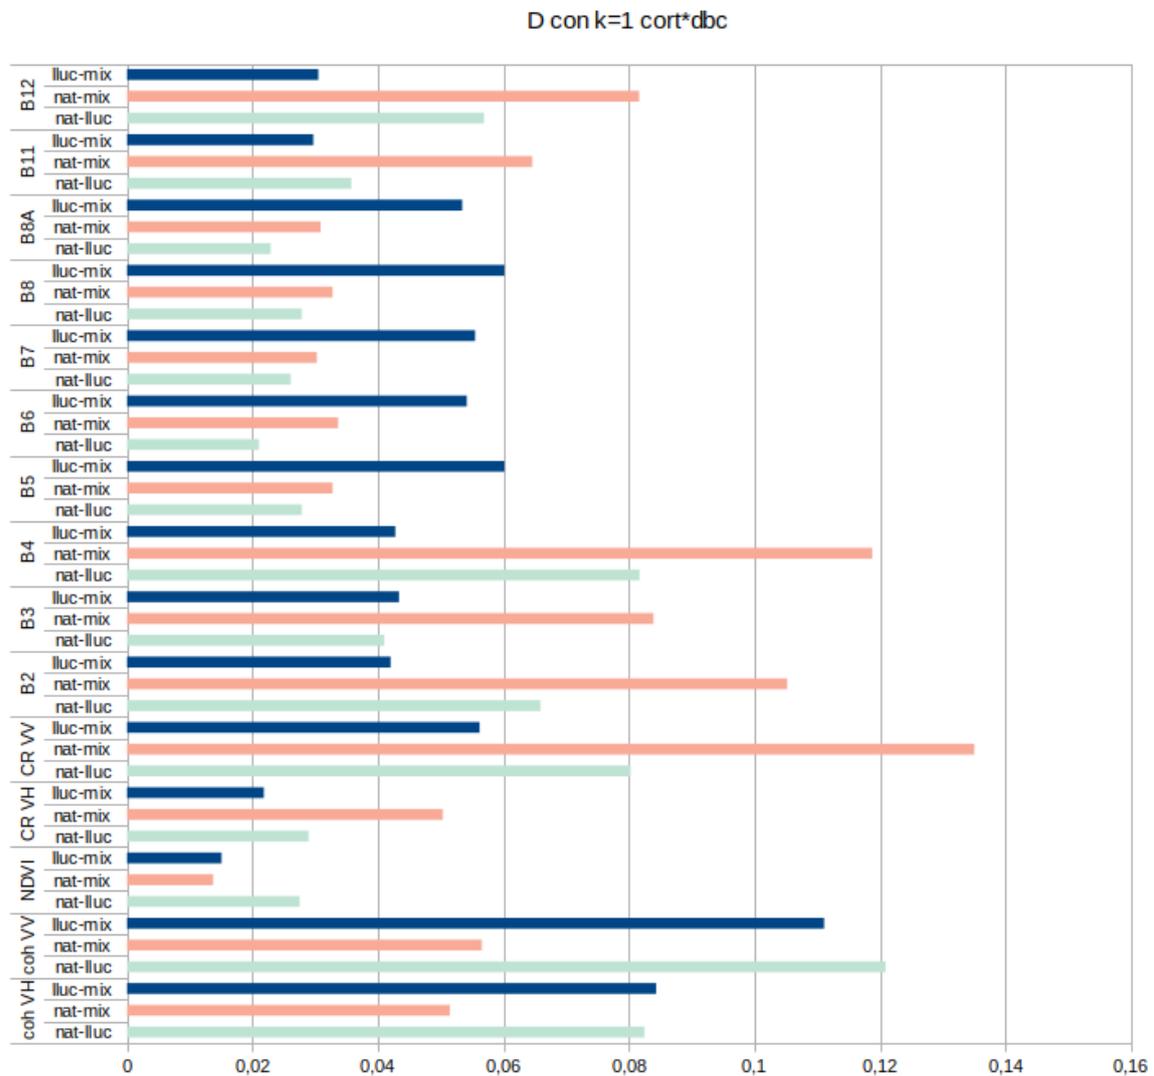


Figura 5.8: Coeficiente de disimilitud D con k=1 entre pares de clases por variable

Se observó que para determinadas series temporales, pares de clases que según el análisis marginal no se pueden diferenciar, según el análisis temporal muestran la mayores diferencias.

5.3. Clasificaciones

Para todas las clasificaciones, los resultados de precisión pueden observarse en las Fig. 5.16 y 5.17.

5.3.1. Árboles de decisión

Las clasificaciones con árboles de decisión arrojan resultados poco precisos, como lo indican sus valores de PG y K (Fig. 5.16 y 5.17). Estos valores de PG fueron menores a los alcanzados en las clasificaciones de Gavier-Pizarro et al.[9] y Hoyos et al. [4] (84% y 89% respectivamente). Sin embargo, puede observarse que coinciden con los resultados esperados, ya que píxeles de las clases *lluc* y *mix* se encuentran en sitios cercanos a cursos de agua, en los que en la bibliografía se reporta la presencia de *L.lucidum* (ver 2.2.1) (Fig. 5.9). La baja precisión puede estar relacionada entonces a píxeles que con este método quedan sin clasificar, aumentando los errores de omisión de las tres clases.

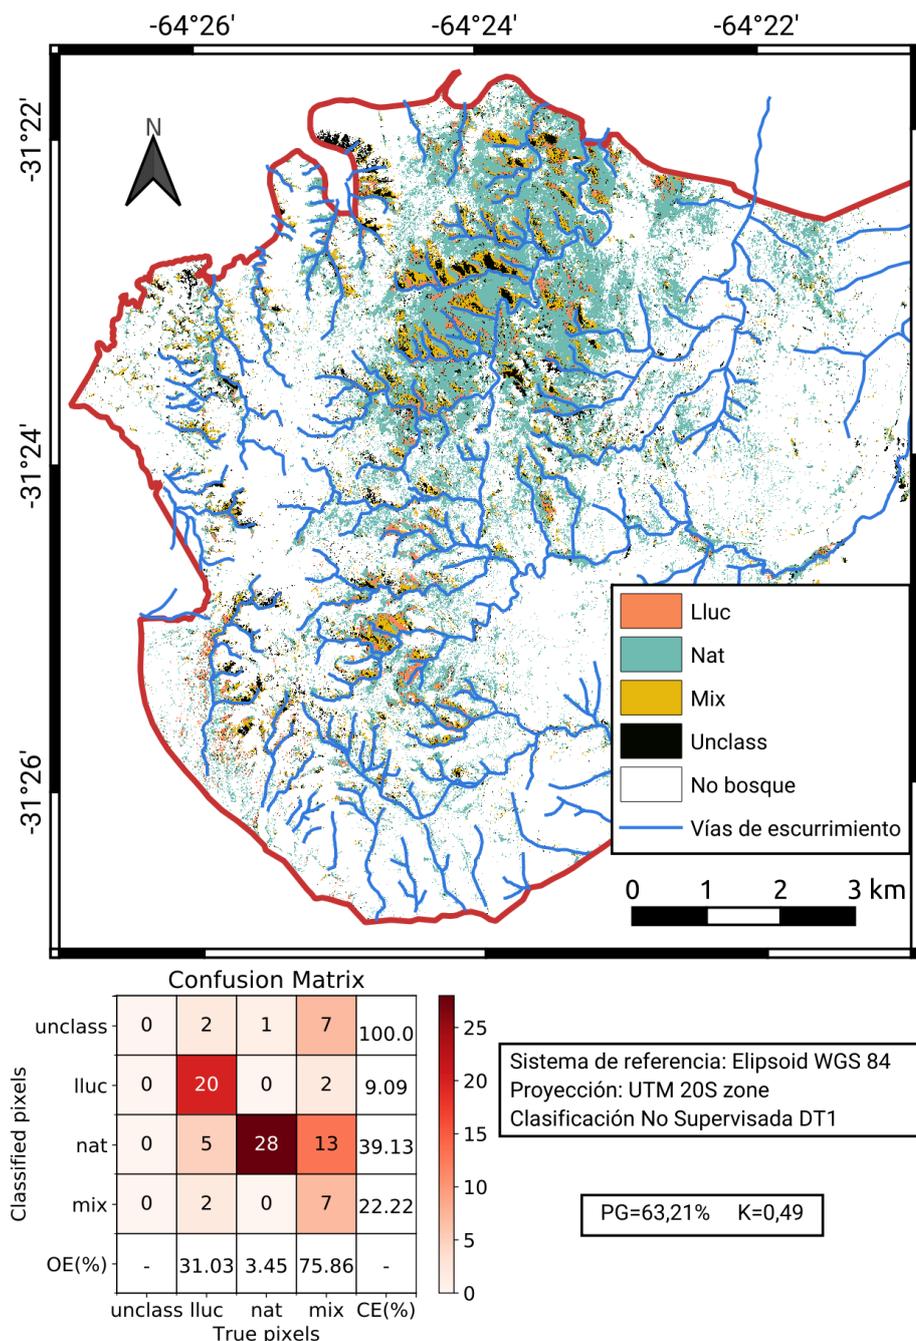


Figura 5.9: Clasificación obtenida con DT1

Al considerar las medias y desvíos estándar de todas las variables (DT1, DT2 y DT3), mien-

tras aumenta el umbral (th), aumenta la cantidad de píxeles sin clasificar. Es por ello que los mejores resultados se obtienen con el menor umbral (0.3) en la clasificación DT1 (ver Fig. 5.9) que tiene PG=63.21 % y el K=0.49. El mayor error es el de omisión de la clase *mix*, cuyos píxeles son asignados a la clase *nat* o no son clasificados. Esto conlleva a una subestimación de área con presencia de exóticas. Este error podría disminuirse cambiando la regla de asignación de píxeles a la clase *mix*, que se muestra en la Fig. 4.9.

Con las clasificaciones DT4 y DT5, la precisión obtenida fue más baja a la obtenida con las medias y desvíos estándar de todas las variables (PG=52,9, K= 0.39 DT4; OA=47.1 , K=0.27 DT5). Por lo tanto, una simplificación en las variables de entrada genera una pérdida en la precisión de la clasificación.

5.3.2. Random Forest y Support Vector Machine

En cuanto a los resultados obtenidos para una misma serie temporal, pero con distintos clasificadores de machine learning (RF o SVM), puede observarse que la precisión de las clasificaciones es similar (Fig. 5.16 y 5.17), aunque con SVM quedan píxeles sin clasificar y no así con RF.

Las clasificaciones con estos clasificadores para cada serie temporal individual arrojan resultados muy precisos (con precisiones globales entre 75 y 97%), pero en las imágenes resultantes puede observarse que sobreestiman el área cubierta por *lluc* y *mix*, cubriendo estas clases la mayor parte del área de estudio y sin seguir un patrón esperado en función de la distribución de *L.lucidum* reportada en bibliografía (ver 2.2.1) y observada en recorridas de campo. Esto puede deberse a que la cantidad de píxeles de entrenamiento no es suficiente y su distribución en el espacio no es aleatoria. Estos valores de PG fueron similares y en algunos casos mayores a los alcanzados en las clasificaciones de Gavier-Pizarro et al.[9] y Hoyos et al. [4] (84 % y 89 % respectivamente)

La clasificación de las series temporales de Coherencia en VV (Fig. 5.10) y en VH son las que arrojan resultados más precisos (PG=91.95 K=0.88 Coh VH - RF; PG= 95.40 K=0.93 Coh VH - SVM; PG=95.40 K= 0.93 Coh VV - RF; PG=96.55 , K=0.95 Coh VV - SVM) y que visualmente coinciden con la distribución esperada de las clases *lluc* y *mix* en función de la distribución de *L. lucidum* reportada en bibliografía (ver 2.2.1).

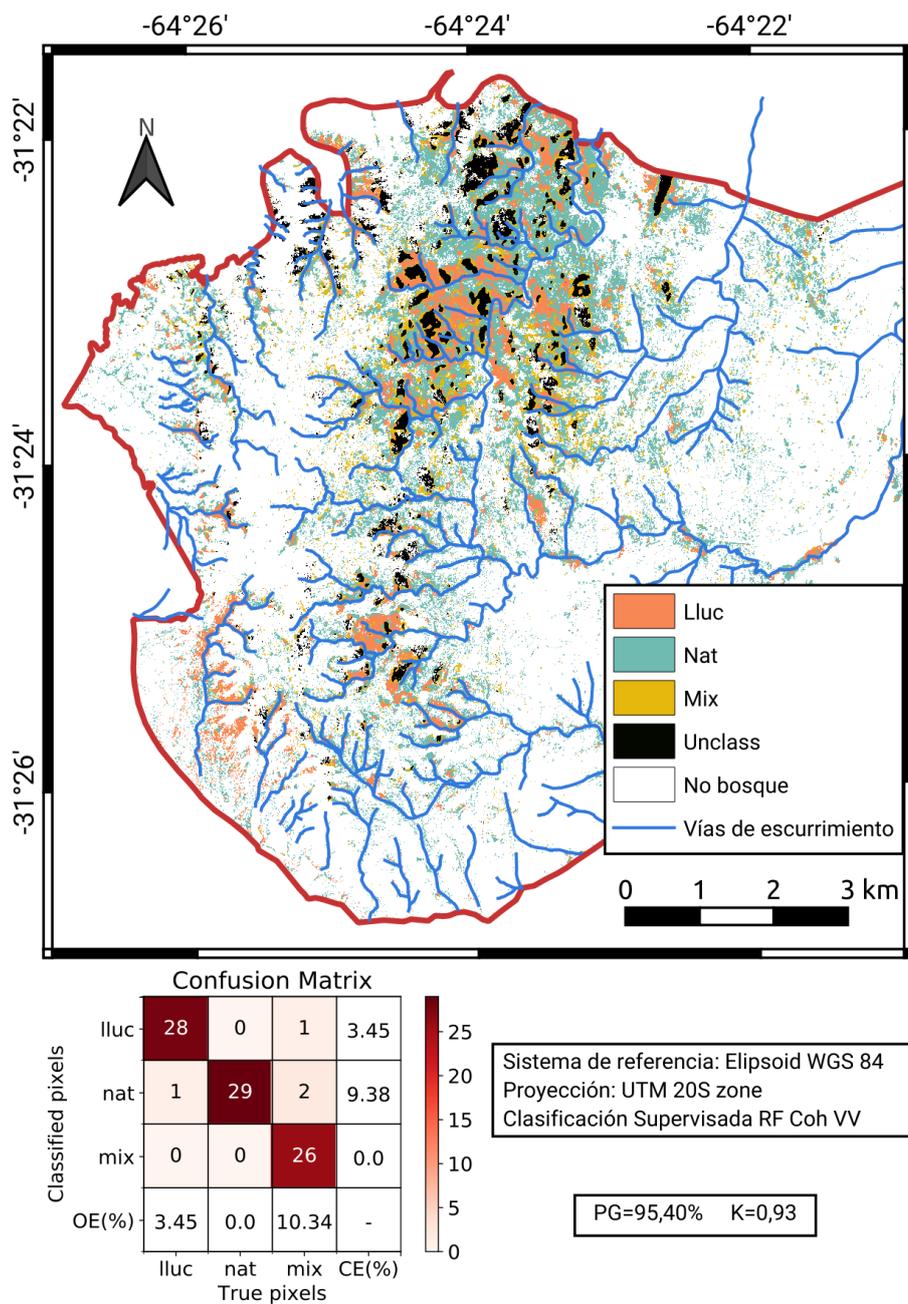


Figura 5.10: Clasificación obtenida con RF - Coh VV

Por otro lado, las clasificaciones de series temporales de NDVI arrojan resultados menos precisos (OA=74.71 , K= 0.62 NDVI - RF; OA=77.01 , K=0.66 NDVI - SVM) pero parecieran no sobreestimar la superficie cubierta por *lluc* y *mix*.

Por último, las clasificaciones de series temporales de coeficiente de retrodispersión SAR (Fig. 5.11) resultan con precisiones similares a las obtenidas con NDVI (PG=75.86 , K=0.64 CR VV - RF; PG=74.71 , K=0.625 CR VV - SVM; PG=78.16 , K=0.67 CR VH - RF, PG=80.45 , K=0.71 CR VH - SVM), pero no se observa ningún patrón. Las clases *lluc* y *mix* cubren la mayor parte del área de estudio. Para esta situación, se plantean dos posibles causas: o bien los tipos de bosque en estudio no presentan diferencias en su respuesta en la banda C que permita su clasificación; o el método de filtrado del ruido speckle no fue el adecuado.

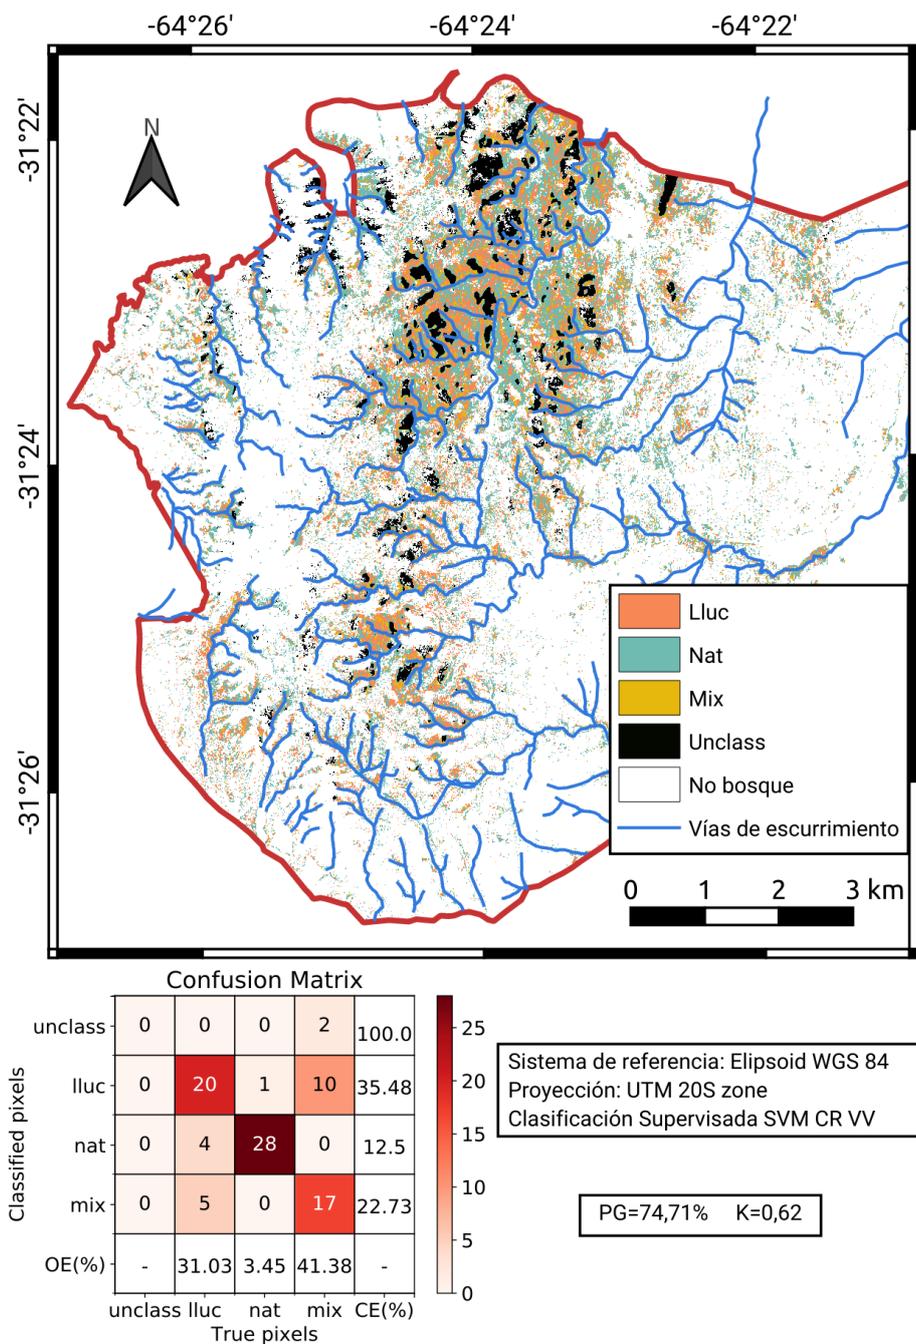


Figura 5.11: Clasificación obtenida con SVM - CR VV

El patrón observado (distribución de las clases con *L. lucidum lluc* y *mix*) en la imagen resultante mejoró cuando se combinaron datos SAR y ópticos, y la precisión se mantiene alta. Al realizar la clasificación con las series de NDVI y Coherencia en VH o Coherencia en VV con el clasificador RF se obtienen los mejores resultados (PG=88.5 , K=0.83 NDVI + Coh VH - RF y PG=93.10 , K=0.90 NDVI + Coh VV - RF). En las imágenes resultantes pareciera observarse menor sobreestimación de cobertura de las clases *lluc* y *mix* con respecto a las otras clasificaciones (Fig. 5.12 y 5.13). Por otro lado, esta combinación de SAR y óptico permite clasificar los píxeles que al utilizar sólo datos SAR habían quedado enmascarados por sombra o layover.

Cuando se clasificó la combinación de las series temporales de reflectancia en Banda 2, Coherencia VH y NDVI la precisión disminuyó con respecto a las precisiones obtenidas al clasificar la combinación de NDVI y Coh VH (PG=85,05, K=0,77 NDVI+B2+Coh VH - RF;

PG=82,75, K=0,74 NDVI+B2+Coh VH - SVM). Esto demuestra que la adición de información de entrada a los clasificadores no siempre redundaba en una mejora en las clasificaciones.

Cuando se clasificó la combinación de series de datos SAR (CR y Coh VH) la precisión no mejoró con respecto a la de las clasificaciones de las series clasificadas individualmente con el clasificador SVM (PG=81,60 K=0,72 Coh VH+CR VH-SVM). Por el contrario, con el clasificador RF la precisión si mejoró (PG= K= Coh VH+CR VH-RF), pero en la imagen resultante la clase *mix* cubre casi toda el área de estudio, en discrepancia con la distribución de la especie (*L. lucidum*) informada en la bibliografía (ver 2.2.1).

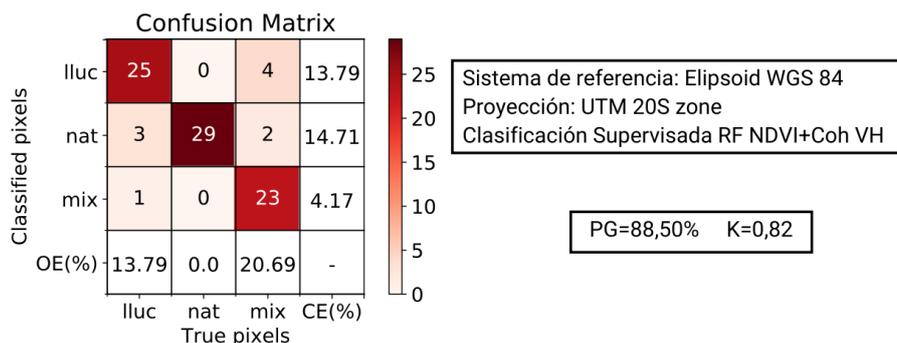
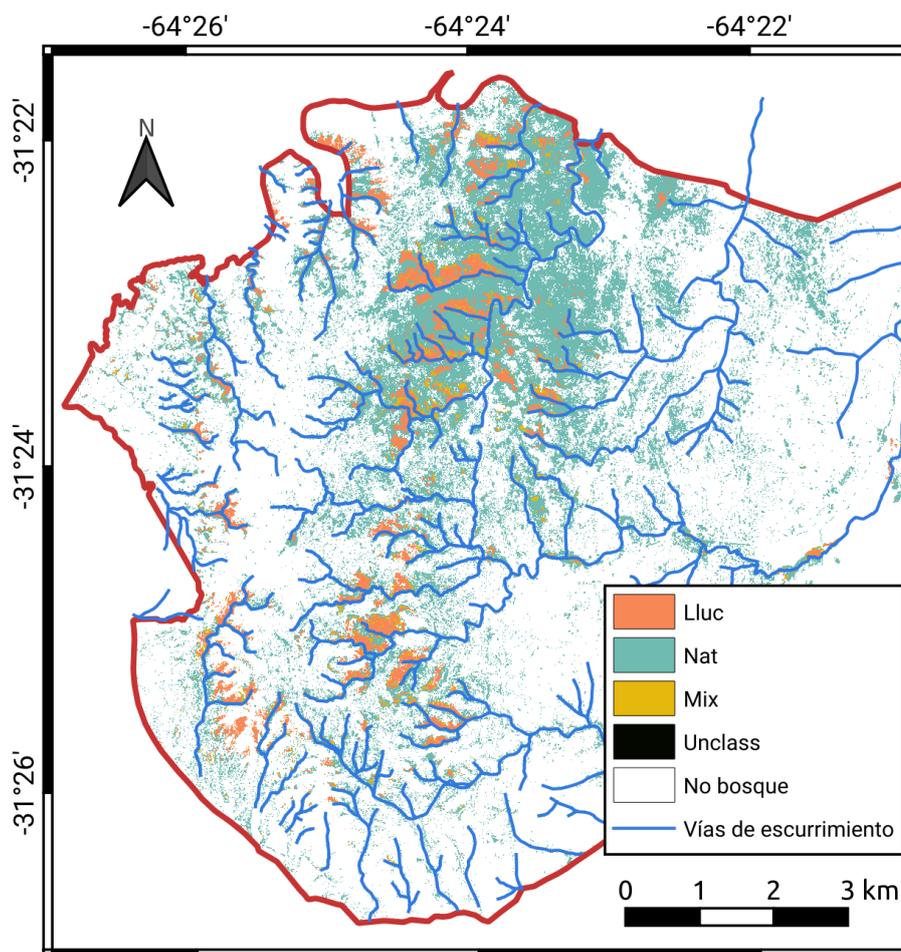


Figura 5.12: Clasificación obtenida con RF - NDVI+Coh VH

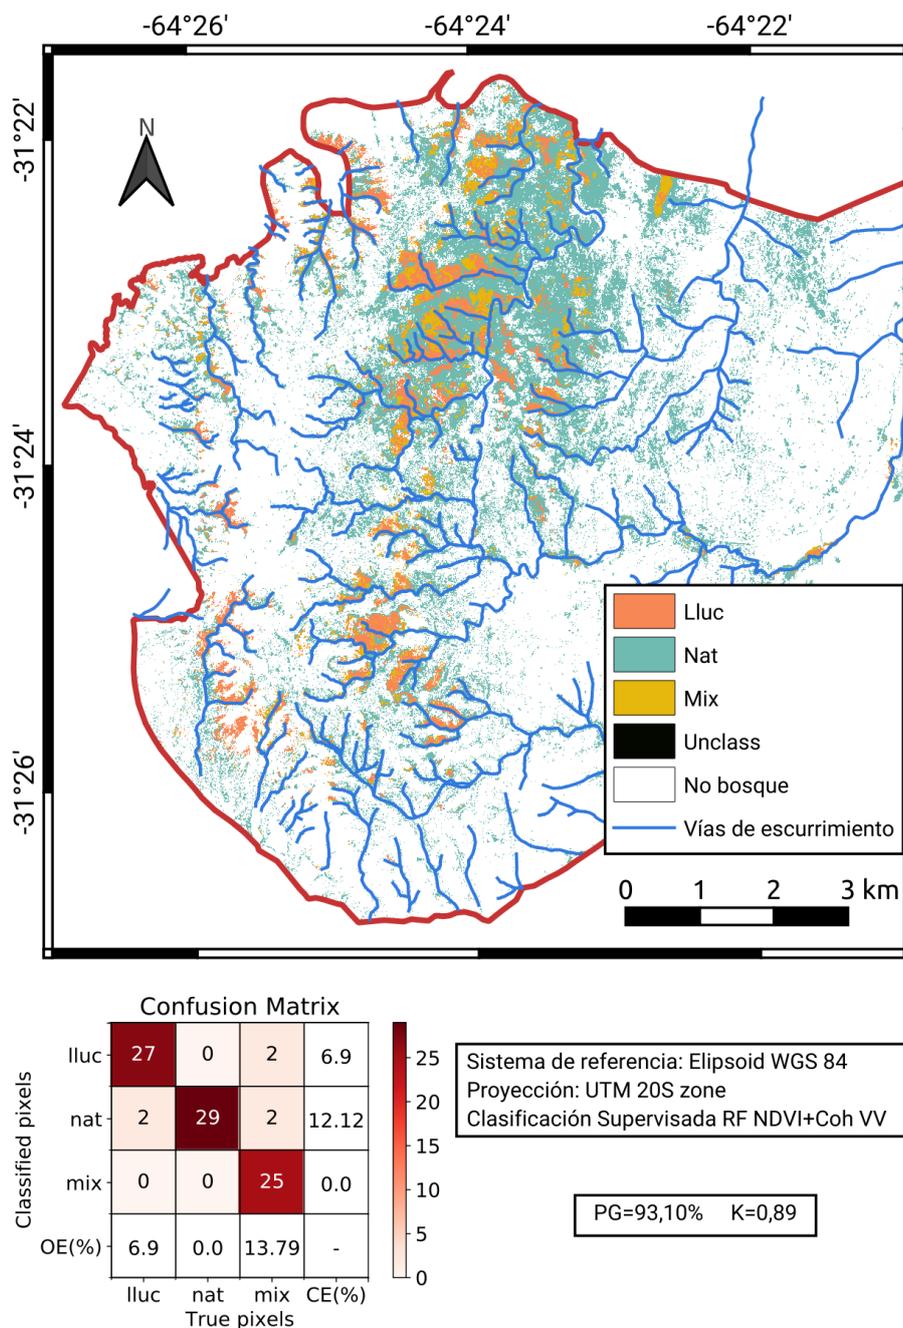


Figura 5.13: Clasificación obtenida con RF - NDVI+Coh VV

5.3.3. Análisis discriminante

La precisión obtenida al clasificar las series temporales individualmente con este clasificador fueron regulares a buenas (PG entre 60 y 89% y Kappa entre 0.41 y 0.84), aunque se observó que sobreestiman el área cubierta por *lluc* y *mix*. Con respecto a las clasificaciones obtenidas con los otros clasificadores, con el ADL mayor cantidad de píxeles son clasificados como *mix*. Los valores de PG obtenidos fueron menores o iguales a los alcanzados en las clasificaciones de Gavier-Pizarro et al.[9] y Hoyos et al. [4] (84% y 89% respectivamente)

De las clasificaciones de series temporales individuales, las de las series de coherencias son las que arrojan mejores precisiones (PG=88,50 K=0,82 Coh VH - ADL; PG=89,65 K=0,84 Coh VV - ADL). En la imagen obtenida al clasificar la serie de Coherencia VH se observó

menor sobreestimación del área cubierta por *lluc* y *mix* que el la obtenida al clasificar la serie de Coherencia VV.

Al clasificar la serie temporal de NDVI, se obtuvieron valores similares de precisión y coherencia que con RF y SVM (PG=74,71 K=0,62 NDVI - ALD).

Al igual que con RF y SVM, las clasificaciones de series temporales de Coeficiente de retrodispersión arrojan resultados poco precisos, incluso con valores de precisión aún más bajos (PG=64,36 K=0,46 CR VH- ADL; PG=64,36 K=0,46 CR VV- ADL). En las imágenes resultantes, las clases *lluc* y *mix* están distribuidas en el área de estudio, sin un claro patrón de distribución esperado en función de los sitios cubiertos por *L.lucidum* reportados en bibliografía (ver 2.2.1).

Al combinar y clasificar las series temporales de NDVI y Coherencia con ADL aumentan la precisión y el Kappa (PG=91,95 K=0,87 NDVI+Coh VH - ADL; PG=96,55 K=0,94 NDVI+Coh VV - ADL)(Fig. 5.15), con respecto a cuando las series temporales son clasificadas individualmente. Esta mejora en la precisión al combinar datos ópticos y SAR coincide con Blaes et. al [50]. En estas clasificaciones también mejora la distribución de los píxeles de las clases *mix* y *lluc*. La Fig. 5.14 es el gráfico del espacio bidimensional generado en el ADL. El agrupamiento entre píxeles de la misma clase, y la separación entre los grupos de las distintas clases indica que estas son lo suficientemente diferentes como para ser diferenciadas por el método del ADL. Solamente un píxel de la clase *mix* fue erróneamente agrupado con la clase *lluc* (el punto amarillo dentro del grupo de puntos rosados).

La precisión mejoró cuando se combinaron las series temporales de NDVI, Coherencia VH y reflectancia en B2; las series de Coherencia VH y Coeficiente de retrodispersión VH o las series de NDVI con las de Coeficiente de retrodispersión, con respecto a las clasificaciones de la series temporales individuales (PG=91,95 K=0,87 NDVI+B2+Coh VH - ADL; PG=94,25 K=0,91 Coh VH+CR VH - ADL; PG=80,45 K=0,70 NDVI+CR VH - ADL; PG=75,86 K=0,63 NDVI+CR VV - ADL). Sin embargo, las clases *lluc* y *mix* se encontraron cubriendo gran parte de la superficie en estudio.

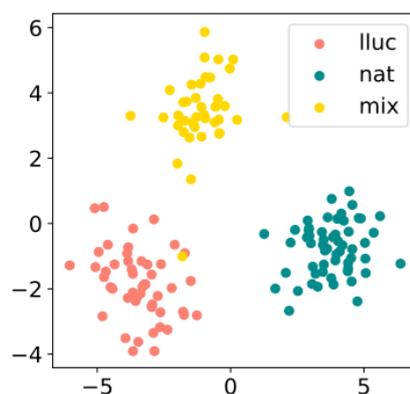


Figura 5.14: Espacio transformado ADL

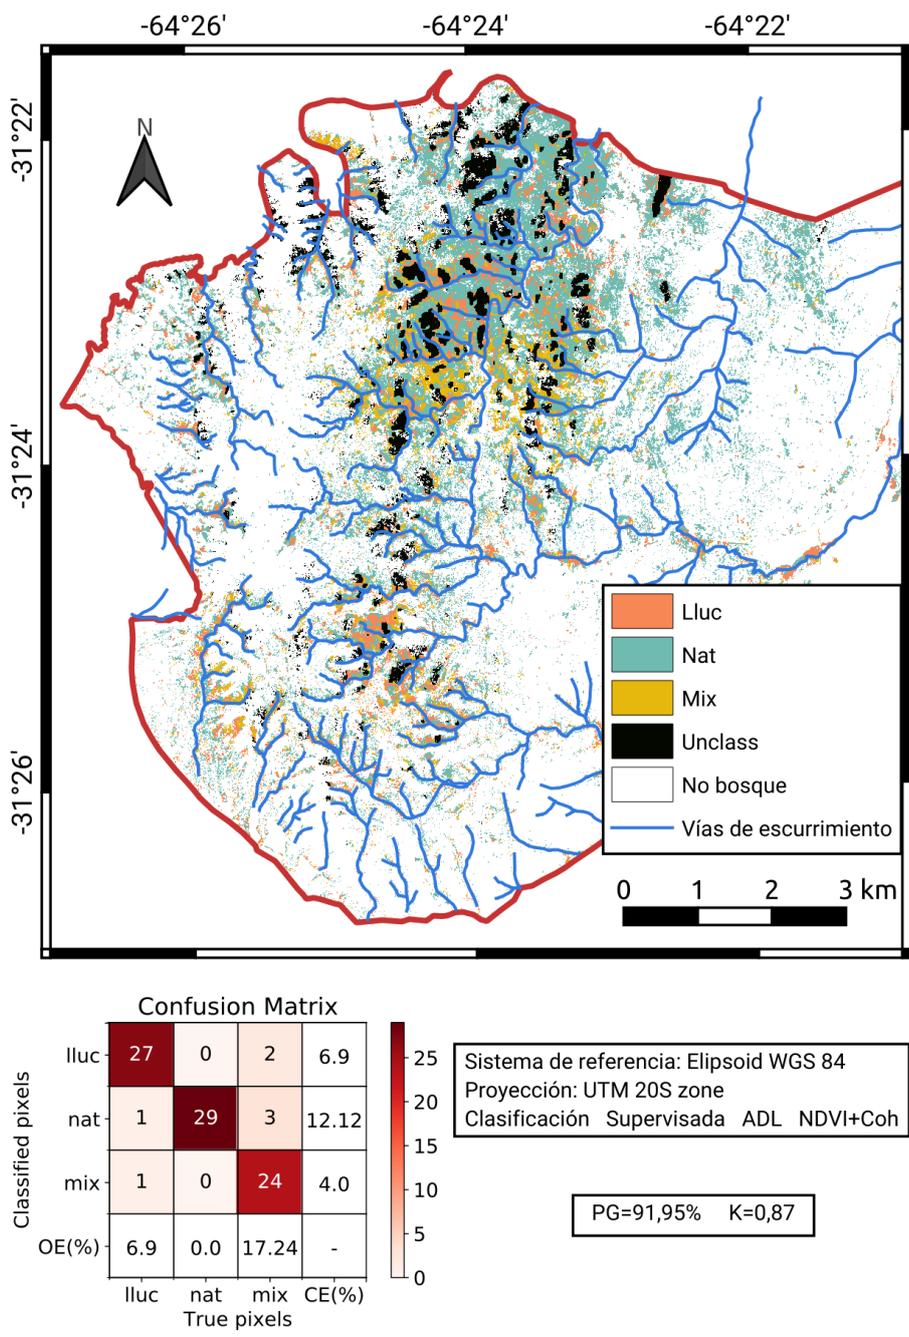


Figura 5.15: Clasificación obtenida con ADL - NDVI+Coh VH

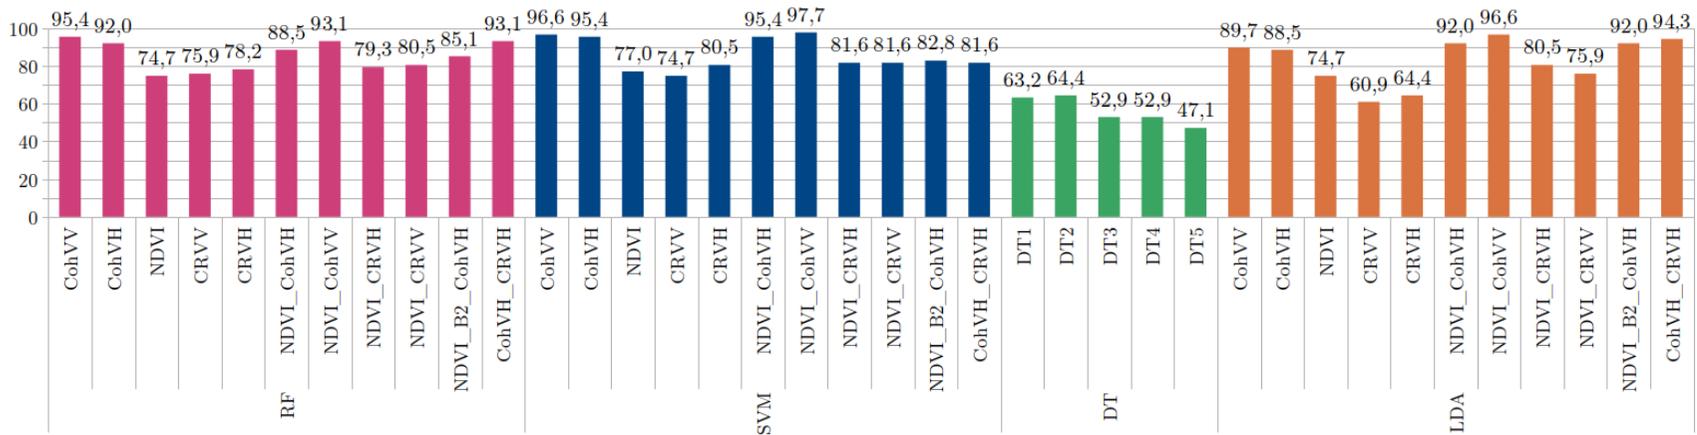


Figura 5.16: Precisión Global (%)

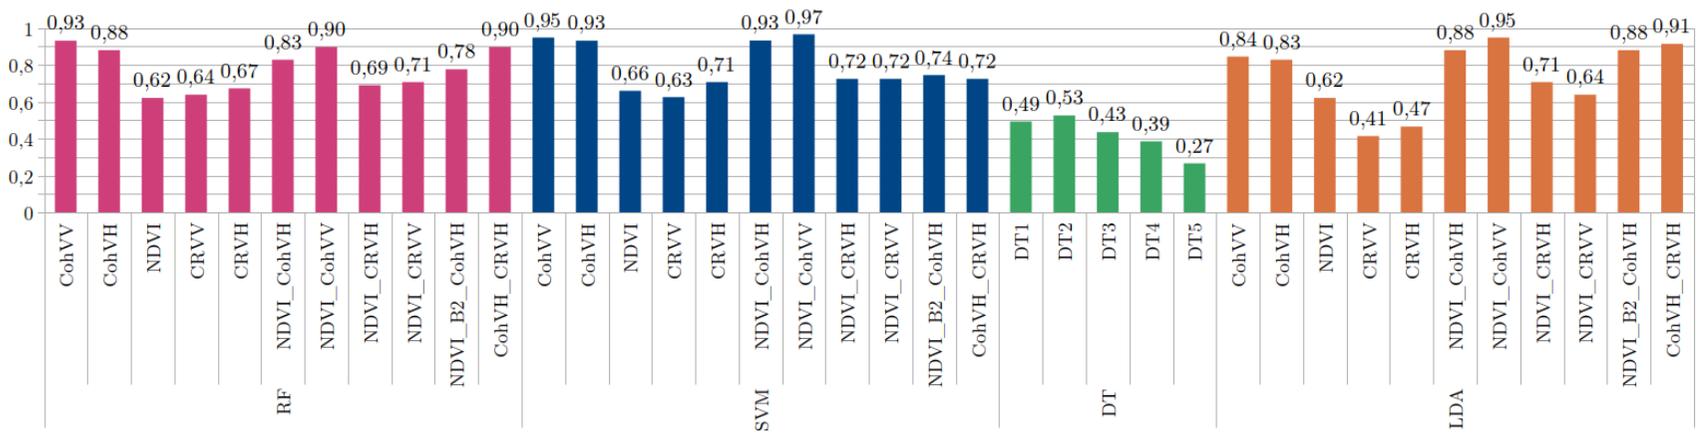


Figura 5.17: Índice Kappa

Se encontró además que el coef D (Fig. 5.8) está relacionado con los valores de precisión y Kappa (Figuras 5.16 y 5.17). Las series que presentaban mayores valores de D generaron clasificaciones más precisas (Coh VH, Coh VV), mientras que las de menores valores de D las precisiones más bajas (NDVI y CR VH). Para la serie de CR VV esta relación es inversa, ya que el D es alto y la precisión de la clasificación, baja.

5.4. Interpretación geográfica de las clasificaciones

En esta sección se analizan las imágenes seleccionadas que se detallan en la Tabla 4.7.

La Figura 5.18 muestra la localización de vías de escurrimiento, red vial, áreas urbanas y pendientes considerados para este análisis.

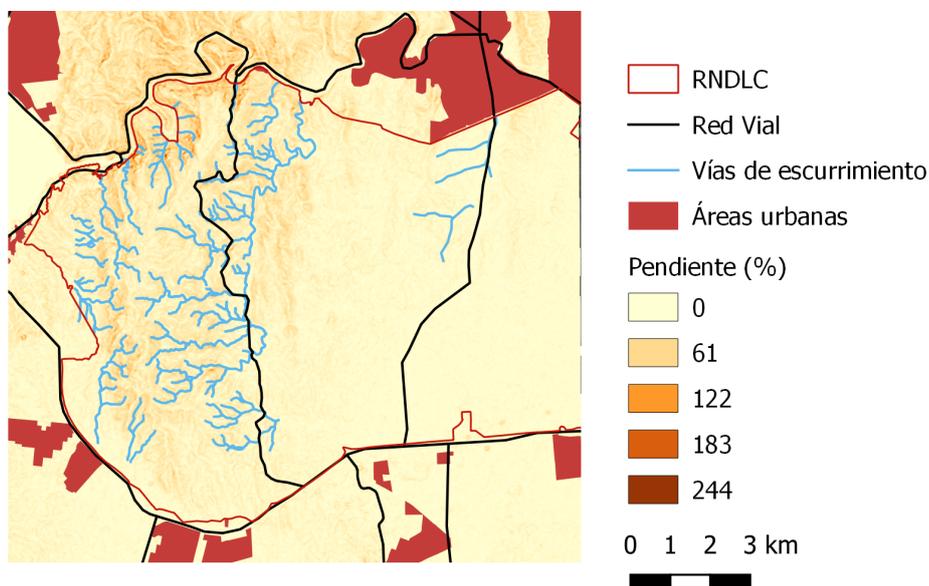


Figura 5.18: Vías de escurrimiento, red vial, áreas urbanas y pendientes

La Fig. 5.19 muestra la proporción de los píxeles de las clases de bosque de Karlin et al. [22] clasificados como *lluc*, *nat* y *mix* en las imágenes seleccionadas. En todas las clasificaciones, predomina la cantidad de píxeles etiquetados como *nat*. Las clasificaciones obtenidas con los clasificadores de ADL y AD presentan al menos un 10% de píxeles sin clasificar. La clasificación obtenida con ADL es la que posee mayor proporción de píxeles etiquetados como *lluc*, sugiriendo que este clasificador es el que produjo la mayor sobreestimación de área cubierta por esta clase.

La Fig. 5.20 muestra que en las imágenes clasificadas obtenidas con el AD y con RF se encuentra una mayor proporción de píxeles de la clase *lluc* a menos de 100 m de las vías de escurrimiento. Este patrón de distribución es más fuerte en la imagen obtenida con RF que en la obtenida con el AD. Este patrón no es observado en la imagen obtenida con el ADL, donde la mayor proporción de los píxeles de *lluc* se encuentran a más de 100 m de las vías de escurrimiento.

Para todas las imágenes seleccionadas, se encontró una mayor proporción de píxeles de la

clase *mix* a menos de 100 m de las vías de escurrimiento y una mayor proporción de la clase *nat* a más de 100 m de las vías de escurrimiento. Esto puede deberse a que estas zonas húmedas se encuentran invadidas (en mayor o menor grado) por la especie *L. lucidum*. Este resultado coincide con Salazar et al. [20] y Gavier et al. [9] que reportaron la presencia de individuos de *L. lucidum* asociada a cursos de agua y áreas húmedas.

A pesar que Hoyos et al. [4] y Gavier-Pizarro et al. [9] encontraron parches de *L. lucidum* cercanos a áreas urbanas, la Fig. 5.21 muestra que en las clasificaciones no se encontró esta relación. Esto puede ser explicado por dos causas. En primer lugar, en el área de estudio puede no estar presente este patrón ya que, a diferencia del resto de las Sierras Chicas a donde si fue observado, este área protegida cuenta con restricciones de ingreso debido a uso militar desde 1943. La segunda causa puede ser que esta metodología no haya sido capaz de detectar la presencia de *L. lucidum* cercana a áreas urbanas.

Cuando se emplearon los clasificadores RF y AD, se observó la mayor proporción de píxeles de las clases con *lluc* y *mix* en áreas con pendiente mayor al 25% (Fig. 5.22), como se observó en las campañas de campo para la toma de datos de campo. Esta distribución de píxeles no fue observada en la imagen clasificada obtenida con ADL.

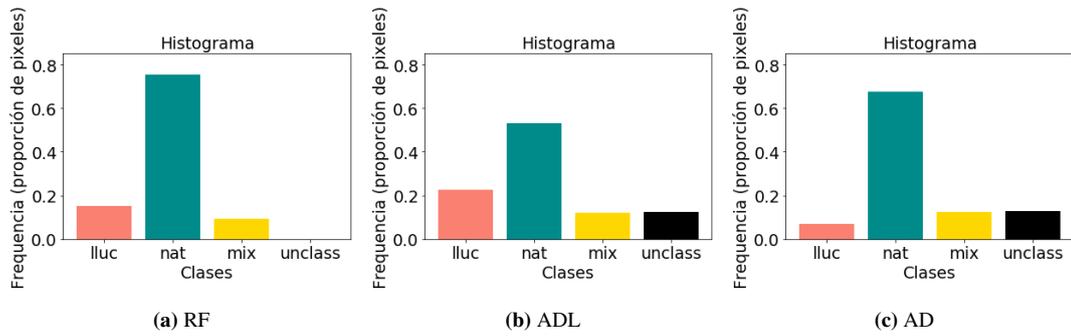


Figura 5.19: Histograma de clases

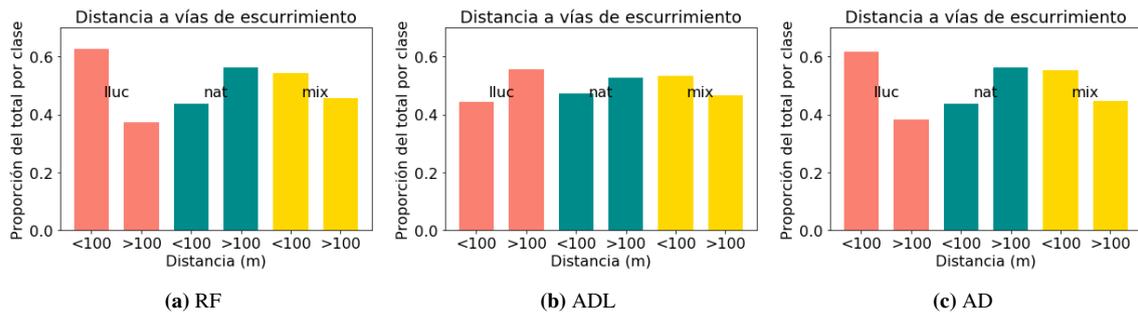


Figura 5.20: Proporción de píxeles a menos o más de 100m de vías de escurrimiento

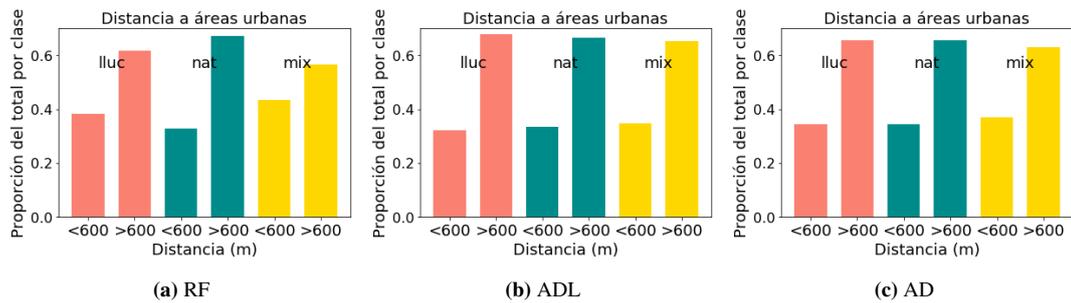


Figura 5.21: Proporción de píxeles a menos o más de 600m de áreas urbanas

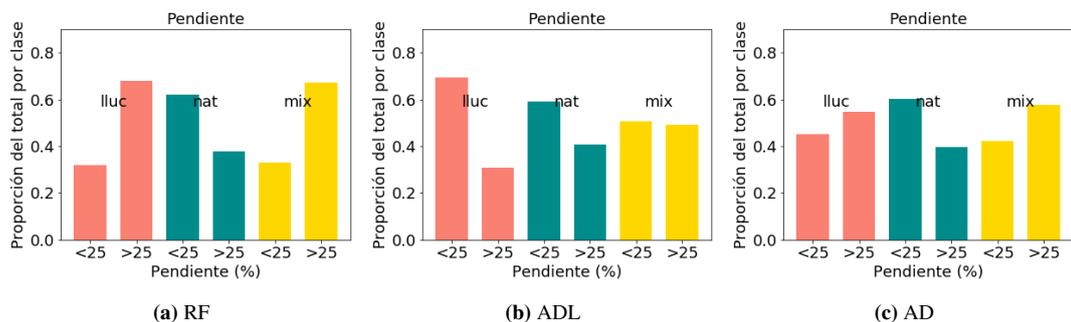


Figura 5.22: Proporción de píxeles sobre áreas con menos o más de 25% de pendiente

5.5. Re-validación de resultados

Fueron relevados con puntos GPS 29 nuevos sitios de muestreo, de los cuales 7 corresponden a la clase *lluc*, 20 a *nat* y 2 a *mix*. Su ubicación se muestra en la Fig. 5.23.

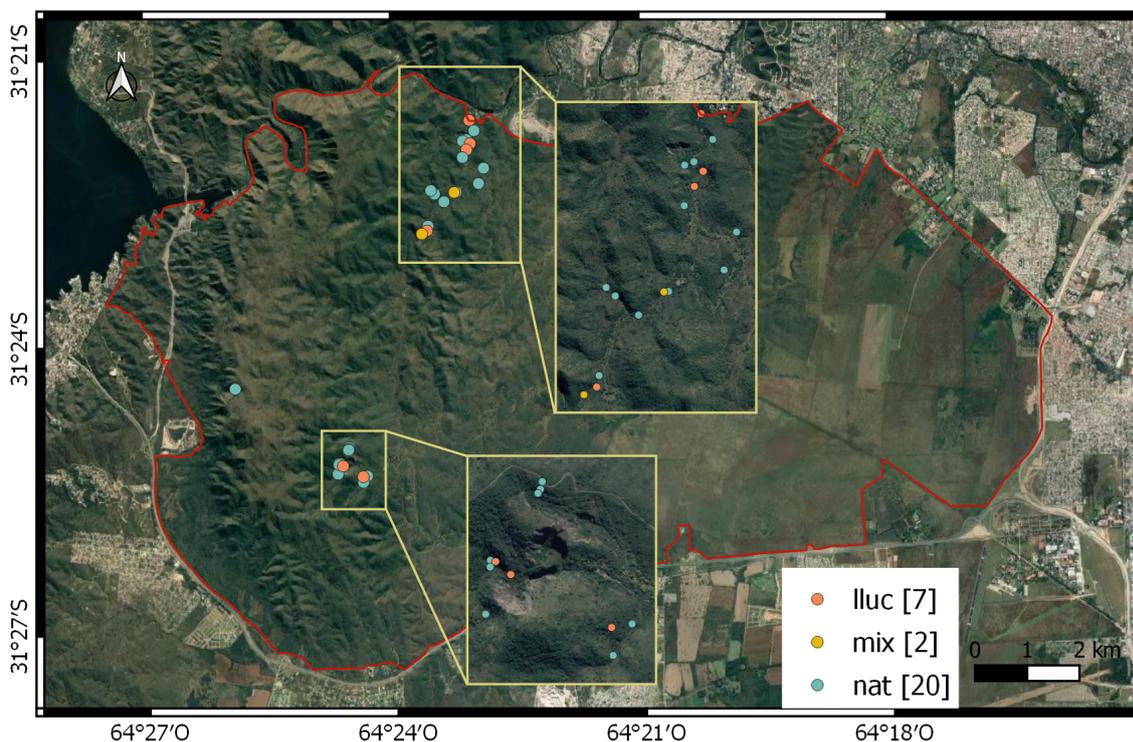


Figura 5.23: Nuevos sitios de muestreo

Las Tablas 5.1, 5.2 y 5.3 muestran la proporción de sitios correctamente clasificados, los errores de omisión y de comisión con los nuevos sitios de validación en las clasificaciones de la Tabla 4.7: RF CohVV+NDVI; ADL CohVH+NDVI y AD1.

Para estos sitios, la clasificación obtenida con RF es la que produce la mayor proporción de sitios bien clasificados al igual que como sucedió con el set de datos de validación utilizado previamente (Sección 4.5). Sin embargo, para todos los casos esta nueva PG con sitios de re-validación es menor a la PG obtenida previamente: 58,6% vs. 93,10% para RF CohVV+NDVI; 51,7% vs. 91,95% para ADL CohVH+NDVI y 51,7% vs. 63,21% para AD1.

Con ninguno de los 3 clasificadores fueron bien clasificados los sitios de la clase *mix*, que en las clasificaciones fueron asignados a la clase *nat*. Con todos los clasificadores la clase *nat* es la que presenta menor error tanto de omisión como de comisión.

Estas diferencias en valores de PG sugieren que la robustez de los clasificadores aún debe ser evaluada en otros sitios con características florísticas, edáficas y climáticas similares.

Tabla 5.1: Validación RF CohVV+NDVI

	lluc	nat	mix	ec
lluc	3	4	0	57,14
nat	4	14	2	30
mix	0	2	0	100
eo	57,14	30	100	
PG=58,6%				

Tabla 5.2: Validación ADL CohVH+NDVI

	lluc	nat	mix	ec
lluc	3	7	0	70
nat	3	12	2	29,4
mix	1	1	0	100
eo	57,14	40	100	

PG=51,7%

Tabla 5.3: Validación AD1

	lluc	nat	mix	ec
lluc	1	3	0	75
nat	6	14	2	36,36
mix	0	3	0	100
eo	85,71	30	100	

PG=51,7%

Conclusiones

Luego de los análisis expuestos en las secciones anteriores se desprenden las siguientes conclusiones:

Las especies arbóreas cuyas coberturas dieron origen a las clases (*L. lucidum*, *L. molleoides* y *S. commersoniana*) mostraron características fisiológicas, morfológicas y estructurales que se manifestaron en información derivada de sensores remotos. La diferencia en el tamaño de las hojas y la rugosidad de la corteza se observó en las series temporales de coeficiente de retrodispersión, que fue menor para las especies de la clase *nat* con hojas más pequeñas y corteza rugosa. Por otra parte, las diferencias en el color de las hojas, y el cambio de color de verde a rojizo en la clase *nat* por la presencia de individuos de *S. commersoniana* se vio reflejado en los menores valores de la serie temporal de NDVI. Las diferencias en la tasa de crecimiento se observaron en las series temporales de Coh, siendo menores los valores para la clase *lluc* que presenta la especie de mayor tasa de crecimiento (*L. lucidum*). Además, el comportamiento de estas series también permiten concluir que las especies nativas detienen su crecimiento en los meses de la estación seca, mientras que *L. lucidum* continua creciendo y consumiendo agua cuando este recurso es escaso.

En cuanto al análisis de relación entre el coeficiente D y las medidas de precisión PG y K , se podría profundizar en su estudio. En caso de encontrar una correlación positiva podría utilizarse a este indicador D para seleccionar las series temporales que mejores resultados podrían dar en las clasificaciones y así ahorrar el costo computacional y de tiempo de realizar todas las clasificaciones posibles.

En síntesis, los resultados mostraron que si los clasificadores que se van a emplear toman a cada píxel como un vector, las medidas más adecuadas para evaluar la separabilidad de clases son las de distancias entre vectores (como D) y no las de estadística marginal.

La clasificación de series temporales de datos ópticos y SAR con los clasificadores AD, SVM, RF y ADL permitieron diferenciar bosques nativos invadidos por *L. lucidum* con distintos niveles de precisión en el centro de Córdoba, Argentina. En cuanto a los indicadores de calidad de las mismas (PG y K) se concluye que no deben ser los únicos parámetros evaluados. Clasificaciones que arrojaron estos valores de precisión similares o mejores a los obtenidos en bibliografía, no mostraron un patrón de distribución de las clases con *L. luci-*

dum (*lluc* y *mix*) como se esperaba en base a lo encontrado por otros investigadores. Quedó demostrado que es importante evaluar también la apariencia de los resultados obtenidos a partir del conocimiento de la situación a campo. Ambos enfoques, basados o en la teledetección o en relevamientos de campo, son complementarios y no excluyentes para el monitoreo de bosques.

Con respecto a los clasificadores probados, pareciera que no tiene sentido realizar el esfuerzo de crear clasificadores de árboles de decisión basados en umbrales. El motivo es que generan las clasificaciones menos precisas y se consume mucho tiempo y esfuerzo en su creación. Además, los clasificadores RF, SVM, ADL parecen ser más adecuados para clasificaciones de series de tiempo, ya que permiten explotar la dimensionalidad temporal al tomar a cada píxel como un vector en el que cada elemento corresponde al valor de la variable que adquiere ese píxel en una fecha determinada. Con estos clasificadores los resultados obtenidos fueron más precisos. Además, la aplicación de estos clasificadores es relativamente sencilla con el lenguaje de programación interpretado de código abierto Python mediante funciones y programas creadas por distintos colaboradores del lenguaje. Existe adecuada documentación para usar estas funciones y programas.

A pesar que los resultados de precisión obtenidos de las clasificaciones fueron muy buenos, la re-validación de las mismas en nuevos sitios con iguales características florísticas, edáficas y climáticas mostró una disminución en la proporción de sitios bien clasificados con respecto a los valores de PG. Se requieren nuevos estudios para probar la robustez de los clasificadores con nuevos datos de campo del mismo área de estudio, o en otra con características florísticas similares. Debido a que la metodología fue programada en Python, la reproducción con nuevos datos de campo será rápida y sencilla.

Los mejores resultados de clasificaciones se obtuvieron al clasificar series de temporales de Coh. Sumado a esto, como se mencionó anteriormente, también se encontró que se relacionan con la tasa de crecimiento y que representan correctamente el ciclo de anual de la vegetación. Se concluye entonces que son una herramienta que podría ser útil para estudios de fenología de la vegetación (de distintos estratos, no sólo bosque) y detección de cambios. Como trabajos a futuro, se proponen: el uso de otros sensores con diferente longitud de onda, resolución espacial y resolución temporal (como SAOCOM y Cosmo-Skymed); la evaluación de diferentes tamaños de ventana de estimación de la Coh y el análisis de series temporales de Coh para diferentes estratos de vegetación, afectados por disturbios, con diferentes usos y manejo.

Por último, se desea reiterar que para el desarrollo de esta tesis se emplearon íntegramente imágenes gratuitas y software de código abierto y gratuitos. No se presentaron inconvenientes y se encontró adecuada documentación acerca de las imágenes y los software empleados. Se destaca la importancia de la accesibilidad a estos recursos gratuitos para el desarrollo de la Ciencia.

Referencias bibliográficas

- [1] S. R. Zeballos, M. A. Giorgis, A. M. Cingolani, M. Cabido, J. I. Whitworth-Hulse, and D. E. Gurvich, “Do alien and native tree species from central Argentina differ in their water transport strategy?,” *Austral Ecology*, vol. 39, no. 8, pp. 984–991, 2014.
- [2] J. G. Ehrenfeld, “Effects of exotic plant invasions on soil nutrient cycling processes,” *Ecosystems*, vol. 6, no. 6, pp. 503–523, 2003.
- [3] E. van der Maarel and J. Franklin, *Vegetation ecology*. John Wiley & Sons, 2012.
- [4] L. E. Hoyos, G. I. Gavier-Pizarro, T. Kuemmerle, E. H. Bucher, V. C. Radeloff, and P. A. Tecco, “Invasion of glossy privet (*Ligustrum lucidum*) and native forest loss in the Sierras Chicas of Córdoba, Argentina,” *Biological invasions*, vol. 12, no. 9, pp. 3261–3275, 2010.
- [5] J. M. Diez, C. M. D’Antonio, J. S. Dukes, E. D. Grosholz, J. D. Olden, C. J. Sorte, D. M. Blumenthal, B. A. Bradley, R. Early, I. Ibáñez, S. J. Jones, J. J. Lawler, and L. P. Miller, “Will extreme climatic events facilitate biological invasions?,” *Frontiers in Ecology and the Environment*, vol. 10, no. 5, pp. 249–257, 2012.
- [6] J. A. Catford, W. K. Morris, P. A. Vesk, C. J. Gippel, and B. J. Downes, “Species and environmental characteristics point to flow regulation and drought as drivers of riparian plant invasion,” *Diversity and Distributions*, vol. 20, no. 9, pp. 1084–1096, 2014.
- [7] S. Baeza, P. Baldassini, C. Bagnato, P. Pinto, and J. Paruelo, “Caracterización del uso/cobertura del suelo en Uruguay a partir de series temporales de imágenes MODIS,” *Agrociencia Uruguay*, vol. 18, no. 2, pp. 95–105, 2014.
- [8] J. D. Lencinas, “Bosques de montaña y teledetección óptica espacial: Desarrollo y perspectivas,” in *Congreso Forestal Mundial*, pp. 18–23, 2009.
- [9] G. I. Gavier-Pizarro, T. Kuemmerle, L. E. Hoyos, S. I. Stewart, C. D. Huebner, N. S. Keuler, and V. C. Radeloff, “Monitoring the invasion of an exotic tree (*Ligustrum lucidum*) from 1983 to 2006 with Landsat TM/ETM+ satellite data and Support Vector Machines in Córdoba, Argentina,” *Remote Sensing of Environment*, vol. 122, pp. 134–145, 2012.

- [10] A. Ferretti, A. Monti Guarnieri, C. Prati, and F. Rocca, “InSAR processing: a practical approach,” *InSAR Principles: Guidelines for SAR Interferometry Processing and Interpretation*; ESA: Paris, France, 2007.
- [11] H. Balzter, “Forest mapping and monitoring with interferometric synthetic aperture radar (InSAR),” *Progress in physical geography*, vol. 25, no. 2, pp. 159–177, 2001.
- [12] L. Sun, J. Chen, S. Guo, X. Deng, and Y. Han, “Integration of time series sentinel-1 and sentinel-2 imagery for crop type mapping over oasis agricultural areas,” *Remote Sensing*, vol. 12, no. 1, p. 158, 2020.
- [13] F. Vicente-Guijalba, A. Jacob, J. Lopez-Sanchez, C. Lopez-Martinez, J. Duro, C. Notarnicola, D. Ziolkowski, A. Mestre-Quereda, E. Pottier, J. J. Mallorquí, M. Lavalle, and M. Engdah, “Sincohmap: Land-Cover and Vegetation Mapping Using Multi-Temporal Sentinel-1 Interferometric Coherence,” in *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*, pp. 6631–6634, IEEE, 2018.
- [14] K. Millard, P. Kirby, S. Nandlall, A. Behnamian, S. Banks, and F. Pacini, “Using growing-season time series of coherence for improved peatland mapping: Comparing the contributions sentinel-1 and radarsat-2 coherence in full and partial time series,” *Remote Sensing*, vol. 12, no. 15, p. 2465, 2020.
- [15] A. W. Jacob, F. Vicente-Guijalba, C. Lopez-Martinez, J. M. Lopez-Sanchez, M. Litzinger, H. Kristen, A. Mestre-Quereda, D. Ziolkowski, M. Lavalle, C. Notarnicola, *et al.*, “Sentinel-1 insar coherence for land cover mapping: A comparison of multiple feature-based classifiers,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 535–552, 2020.
- [16] M. S. Karlin, M. P. Alvarez, S. A. Arnulphi, G. Esmoriz, J. R. Bernasconi Salazar, and A. Cora, “Modelos de escorrentía para la región central de Córdoba,” *IV Jornadas Nacionales de suelos de ambientes semiáridos*, 2019.
- [17] M. A. Giorgis and P. A. Tecco, “Árboles y arbustos invasores de la Provincia de Córdoba (Argentina): una contribución a la sistematización de bases de datos globales,” *Boletín Sociedad Argentina de Botánica*, vol. 49, no. 4, pp. 581–603, 2014.
- [18] M. A. Giorgis, P. A. Tecco, A. M. Cingolani, D. Renison, P. Marcora, and V. Paiaro, “Factors associated with woody alien species distribution in a newly invaded mountain system of central Argentina,” *Biological Invasions*, vol. 13, no. 6, pp. 1423–1434, 2011.
- [19] M. A. Giorgis, A. M. Cingolani, F. Chiarini, J. Chiapella, G. Barboza, L. Ariza Espinar, R. Morero, D. E. Gurvich, P. A. Tecco, R. Subils, and M. Cabido, “Composición florística del Bosque Chaqueño Serrano de la provincia de Córdoba, Argentina,” *Kurtziana*, vol. 36, no. 1, pp. 9–43, 2011.
- [20] J. Salazar, F. Barri, and G. Cardozo, “Distribución espacial y tasa de invasión de flora exótica en la Reserva Natural de Vaquerías–Provincia de Córdoba (Argentina).,” *Quaderni di Botanica ambientale e applicata*, vol. 24, pp. 3–12, 2013.
- [21] R. Aragón and M. Groom, “Invasion by *Ligustrum lucidum* (Oleaceae) in NW Argentina: early stage characteristics in different habitat types,” *Revista de Biología Tropical*, vol. 51, no. 1, pp. 59–70, 2003.

- [22] M. S. Karlin, C. Schneider, S. Rufini, J. Bernasconi, R. Accietto, U. Karlin, and Y. Ferrera, “Caracterización florística de la Reserva Natural Militar Estancia La Calera,” *Nature and Conservation*, vol. 7, no. 1, pp. 6–18, 2014.
- [23] M. S. Karlin, S. Arnulphi, U. Karlin, J. Bernasconi, R. Accietto, and A. Cora, *Plantas del Centro de Argentina*. Ed. ECOVAL, 04 2017.
- [24] P. H. Demaio, M. Medina, and U. O. Karlin, *Árboles nativos del centro de Argentina*. Ed. LOLA, 2002.
- [25] L. Novara, “Euphorbiaceae,” *Aportes Botánicos de Salta-Serie Flora*, vol. 11, no. 18, pp. 1–188, 2013.
- [26] M. G. Franco, M. C. P. Behr, M. Medina, C. Pérez, I. A. Mundo, J. M. Cellini, and M. F. Arturi, “Talaes del NE bonaerense con presencia de *Ligustrum lucidum*: Cambios en la estructura y la dinámica del bosque,” *Ecología Austral*, vol. 28, no. 3, pp. 502–512, 2018.
- [27] L. Profumo, M. Portillo, and I. Mieres, “Crecimiento de *Lithraea molleoides* en dos eco-regiones de Uruguay,” *Recientes avances en investigación para la gestión y conservación del bosque nativo de Uruguay*, pp. 21–23, 2017.
- [28] N. L. Cosmo, “Anatomia ecológica e crescimento do lenho de *Sebastiania commersoniana* (Baillon) Smith & Downs, em diferentes condições geomorfológicas e pedológicas da planície do Rio Iguaçú-PR,” *Tesis de maestría Setor de Ciências Agrárias da Universidade Federal do Paraná*, 2008.
- [29] E. Chuvieco, *Fundamentos de teledetección espacial*, vol. 453. Ediciones Rialp Madrid, 1990.
- [30] J. R. Jensen, *Remote sensing of the environment: An earth resource perspective 2/e*. Pearson Education India, 2009.
- [31] J. Rouse Jr, R. Haas, J. Schell, and D. Deering, “Monitoring vegetation systems in the great plains with erts,” *Third ERTS Symposium, NASA*, vol. SP-351, pp. 309–317, 1973.
- [32] Agencia Espacial Eutopea (ESA), “Sentinel-2 user handbook.” https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook, 2015. (Acceso en 09/10/2019).
- [33] E. S. Agency, “Copernicus open access hub.” <https://scihub.copernicus.eu/dhus/#/home>. (Acceso el 15/04/2019).
- [34] R. Solorza and M. Panozzo Zénere, *Introducción a las aplicaciones de Radar de Apertura Sintética (SAR). Material teórico*. Material de clase. Maestría en Aplicaciones de Información Espacial. IG. CONAE. UNC, 2018.
- [35] A. I. Flores-Anderson, K. E. Herndon, R. B. Thapa, and E. Cherrington, *The Synthetic Aperture Radar (SAR) Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. <https://www.servirglobal.net/Global/Articles/Article/2674/sar-handbook-comprehensive-methodologies-for-forest-monitoring-and-biomass-estimation>, 2019.

- [36] R. F. Hanssen, *Radar Interferometry: Data Interpretation and Error Analysis*. No. 2, Kluwer Academic Publishers, 2001.
- [37] U. Wegmüller, M. Santoro, C. Werner, and O. Cartus, “On the Estimation and Interpretation of Sentinel-1 TOPS InSAR Coherence,” *Proc. of FRINGE, ESA SP-731 (CD-ROM), ESA Publications Division, European Space Agency, Noordwijk, The Netherlands*, 2015.
- [38] L. Veci, “TOPS Interferometry Tutorial,” *Sentinel-1 Toolbox, Array Systems Computing Inc. and European Space Agency*, 2015.
- [39] “SNAP Tutorials | STEP.” <http://step.esa.int/main/doc/tutorials/snap-tutorials/>. Acceso en 13/02/2018.
- [40] Agencia Espacial Europea (ESA), “Sentinel-1 user handbook.” https://sentinel.esa.int/documents/247904/685163/Sentinel-1_User_Handbook, 2013. (Acceso en 15/04/2019).
- [41] M. Krzywinski and N. Altman, “Visualizing samples with box plots.,” *Nature methods*, vol. 11, no. 2, p. 119, 2014.
- [42] J. M. Chambers, W. S. Cleveland, B. Kleiner, and P. A. Tukey, “Graphical methods for data analysis. 1983,” *Wadsworth, Belmont, CA*, vol. 35, 1983.
- [43] M. L. Nores, *Análisis de la Varianza-ANOVA*. Material de clase. Maestría en Aplicaciones de Información Espacial. IG. CONAE. UNC, 2018.
- [44] M. Balzarini, J. A. Di Rienzo, M. Tablada, L. González, C. Bruno, M. Córdoba, W. Robledo, and F. Casanoves, *Introducción a la bioestadística: aplicaciones con InfoStat en agronomía*. No. 570.15195 I61, Editorial Brujas, 2011.
- [45] J. A. Rodrigo, “Rpubs kruskal-wallis test.” https://rpubs.com/Joaquin_AR/219504, 2016. (Acceso el 09/12/2019).
- [46] M. A. Fligner and T. J. Killeen, “Distribution-free two-sample tests for scale,” *Journal of the American Statistical Association*, vol. 71, no. 353, pp. 210–213, 1976.
- [47] A. D. Chouakria and P. N. Nagabhushan, “Adaptive dissimilarity index for measuring time series proximity,” *Advances in Data Analysis and Classification*, vol. 1, no. 1, pp. 5–21, 2007.
- [48] “Scipy python documentation.” <https://docs.scipy.org/doc/scipy/reference/generated/scipy.spatial.distance.braycurtis.html>. (Acceso el 12/06/2019).
- [49] C. Gómez, J. C. White, and M. A. Wulder, “Optical remotely sensed time series data for land cover classification: A review,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 116, pp. 55–72, 2016.
- [50] X. Blaes, L. Vanhalle, and P. Defourny, “Efficiency of crop identification based on optical and SAR image time series,” *Remote sensing of environment*, vol. 96, no. 3-4, pp. 352–365, 2005.
- [51] L. Li, N. Li, D. Lu, and Y. Chen, “Mapping Moso bamboo forest and its on-year and off-year distribution in a subtropical region using time-series Sentinel-2 and Landsat 8 data,” *Remote Sensing of Environment*, vol. 231, p. 111265, 2019.

- [52] P. Mather and B. Tso, *Classification methods for remotely sensed data*. CRC press, 2016.
- [53] V. F. Rodríguez-Galiano and M. Chica-Rivas, “Evaluation of different machine learning methods for land cover mapping of a Mediterranean area using multi-seasonal Landsat images and Digital Terrain Models,” *International Journal of Digital Earth*, vol. 7, no. 6, pp. 492–509, 2014.
- [54] K. Millard and M. Richardson, “On the importance of training data sample selection in random forest image classification: A case study in peatland ecosystem mapping,” *Remote sensing*, vol. 7, no. 7, pp. 8489–8515, 2015.
- [55] M. G. Balzarini, L. González, M. Tablada, F. Casanoves, J. Di Rienzo, and C. Robledo, “Infostat. Manual del usuario,” *Editorial Brujas, Córdoba, Argentina*, p. 336, 2008.
- [56] P. Legendre and L. F. Legendre, *Numerical ecology*, vol. 24. Elsevier, 2012.
- [57] M. Balzarini, C. Bruno, M. Córdoba, and I. Teich, “Herramientas en el análisis estadístico multivariado,” *Escuela Virtual Internacional CAVILA. Facultad de Ciencias Agropecuarias, Universidad Nacional de Córdoba. Córdoba, Argentina*, 2015.
- [58] J. B. Campbell and R. H. Wynne, *Introduction to remote sensing*. Guilford Press, 2011.
- [59] J. A. Richards, *Remote sensing digital image analysis*, vol. 3. Springer, 1999.
- [60] R. G. Pontius Jr and M. Millones, “Death to kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment,” *International Journal of Remote Sensing*, vol. 32, no. 15, pp. 4407–4429, 2011.
- [61] “Reserva natural de la defensa la calera.” <https://www.parquesnacionales.gob.ar/areas-protegidas/reservasnaturalesdeladefensa/ndeladefensalacalera/>. (Acceso en 10/04/2019).
- [62] A. L. Cabrera, *Regiones fitogeográficas argentinas*. Acme, 1976.
- [63] A. Dalmasso, R. Candia, and J. Llera, “La vegetación como indicadora de la contaminación por polvo atmosférico,” *Multequina*, no. 6, 1997.
- [64] R. Capitanelli, “Clima,” *Geografía física de la provincia de Córdoba*, pp. 45–138, 1979.
- [65] J. Gorgas, J. Tassile, B. Jarsún, E. Zamora, H. Bosnero, E. Lovera, and A. Ravelo, “Recursos naturales de la provincia de Córdoba, los suelos: nivel de reconocimiento escala 1: 500.000,” *Agencia Córdoba DAC y TSEM Dirección Ambiente y Instituto Nacional de Tecnología Agropecuaria INTA-Manfredi*, 2003.
- [66] M. S. Karlin, F. Ontibero, S. Arnulphi, and J. B. Salazar, “Caracterización edafológica de la Reserva Natural de la Defensa La Calera, Córdoba (Argentina),” *Multequina*, no. 27, pp. 5–22, 2018.
- [67] J. Braun-Blanquet, “Fitosociología,” *Bases para el estudio de las comunidades vegetales*. Blume, Madrid, 1979.
- [68] C. Krehbiel, “Calculate ndvi from sentinel-2a data.” <https://colekrehbiel.wordpress.com/2017/10/18/calculate-ndvi-from-sentinel-2a-data/>, 2017. (Acceso en 30/10/2019).

- [69] H. Kristen, “landcover_classification.” https://gitlab.inf.unibz.it/SInCohMap/datacubes/blob/ffecd859626959a4a65548c6f1f1a1a1c6e3578a/landcover_classification/landcover_classification.py, 2017. (Accessed on 07/25/2019).
- [70] “Scikit-learn 0.21.2 documentation.” <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>. (Acceso el 07/25/2019).
- [71] “Scikit-learn 0.21.2 documentation.” <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html#sklearn.svm.SVC>. (Acceso el 07/25/2019).
- [72] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [73] “Scikit-learn 0.21.2 documentation.” https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html#sklearn.model_selection.GridSearchCV. (Accessed on 07/25/2019).
- [74] I. G. Nacional, “Capas SIG.” <http://www.ign.gob.ar/NuestrasActividades/InformacionGeoespacial/CapasSIG/>. (Acceso el 08/27/2019).

Medidas resumen de series temporales

Tabla A.1: Medidas resumen de series temporales. Clase *lluc*

Desvío estándar, media, mínimo y máximo calculados para dos periodos: periodo seco (de Abril a Septiembre) y periodo húmedo (Enero-Marzo y Octubre-Diciembre).

	Periodo seco				Periodo húmedo			
	Desvío Estándar	Media	Mínimo	Máximo	Desvío Estándar	Media	Mínimo	Máximo
B12	0,023	0,095	0,036	0,171	0,016	0,089	0,054	0,151
B11	0,034	0,166	0,068	0,254	0,024	0,178	0,127	0,264
B8A	0,042	0,235	0,077	0,393	0,033	0,298	0,204	0,396
B8	0,047	0,230	0,048	0,456	0,038	0,291	0,187	0,435
B7	0,040	0,212	0,057	0,367	0,034	0,270	0,185	0,386
B6	0,034	0,182	0,050	0,306	0,027	0,230	0,157	0,306
B5	0,047	0,230	0,048	0,456	0,038	0,291	0,187	0,435
B4	0,012	0,034	0,001	0,086	0,009	0,031	0,013	0,067
B3	0,010	0,038	0,001	0,069	0,006	0,044	0,021	0,063
B2	0,008	0,022	0,001	0,048	0,005	0,022	0,006	0,040
Coh VH	0,096	0,208	0,024	0,528	0,076	0,178	0,031	0,428
Coh VV	0,111	0,228	0,029	0,618	0,091	0,213	0,041	0,484
NDVI	0,081	0,784	0,455	0,999	0,063	0,815	0,499	0,940
CR VH	2,544	-14,250	-22,012	-6,817	2,370	-13,946	-20,537	-6,183
CR VV	2,562	-8,401	-16,654	-0,775	2,533	-8,231	-14,600	-0,235

Tabla A.2: Medidas resumen de series temporales. Clase *nat*

Desvío estándar, media, mínimo y máximo calculados para dos periodos: periodo seco (de Abril a Septiembre) y periodo húmedo (Enero-Marzo y Octubre-Diciembre).

	Periodo seco				Periodo húmedo			
	Desvío Estándar	Media	Mínimo	Máximo	Desvío Estándar	Media	Mínimo	Máximo
B12	0,046	0,120	0,025	0,221	0,028	0,105	0,050	0,167
B11	0,059	0,193	0,053	0,303	0,039	0,197	0,111	0,281
B8A	0,042	0,213	0,086	0,324	0,036	0,284	0,198	0,391
B8	0,041	0,204	0,076	0,333	0,037	0,273	0,180	0,392
B7	0,038	0,189	0,080	0,291	0,034	0,256	0,177	0,359
B6	0,033	0,166	0,068	0,256	0,029	0,221	0,155	0,312
B5	0,041	0,204	0,076	0,333	0,037	0,273	0,180	0,392
B4	0,022	0,046	0,000	0,110	0,015	0,040	0,010	0,080
B3	0,015	0,046	0,001	0,082	0,010	0,050	0,019	0,072
B2	0,013	0,028	0,000	0,061	0,009	0,028	0,005	0,051
Coh VH	0,109	0,241	0,023	0,627	0,111	0,232	0,032	0,532
Coh VV	0,142	0,306	0,026	0,704	0,132	0,269	0,037	0,674
NDVI	0,126	0,686	0,313	0,998	0,078	0,775	0,460	0,950
CR VH	3,065	-15,551	-26,184	-5,081	3,170	-15,368	-25,881	-3,947
CR VV	3,249	-9,990	-19,169	2,002	3,276	-10,130	-22,224	0,076

Tabla A.3: Medidas resumen de series temporales. Clase *mix*

Desvío estándar, media, mínimo y máximo calculados para dos periodos: periodo seco (de Abril a Septiembre) y periodo húmedo (Enero-Marzo y Octubre-Diciembre).

	Periodo seco				Periodo húmedo			
	Desvío Estándar	Media	Mínimo	Máximo	Desvío Estándar	Media	Mínimo	Máximo
B12	0,027	0,082	0,021	0,195	0,020	0,089	0,053	0,170
B11	0,039	0,140	0,045	0,272	0,029	0,173	0,107	0,281
B8A	0,054	0,177	0,035	0,322	0,047	0,263	0,141	0,411
B8	0,060	0,167	0,019	0,316	0,051	0,252	0,124	0,395
B7	0,050	0,158	0,019	0,287	0,045	0,236	0,120	0,380
B6	0,044	0,137	0,014	0,258	0,037	0,202	0,108	0,328
B5	0,060	0,167	0,019	0,316	0,051	0,252	0,124	0,395
B4	0,015	0,027	0,000	0,104	0,011	0,031	0,009	0,089
B3	0,014	0,030	0,000	0,083	0,010	0,041	0,012	0,079
B2	0,010	0,017	0,000	0,059	0,008	0,022	0,004	0,054
Coh VH	0,110	0,246	0,029	0,639	0,106	0,231	0,027	0,539
Coh VV	0,156	0,317	0,031	0,679	0,116	0,264	0,043	0,581
NDVI	0,091	0,733	0,387	0,997	0,066	0,782	0,507	0,910
CR VH	3,772	-13,471	-25,471	-5,090	3,314	-12,969	-23,442	-4,068
CR VV	3,990	-7,122	-20,350	3,154	3,539	-7,081	-18,145	1,176

Códigos Python

```
# -*- coding: utf-8 -*-
"""
Created on Fri May  3 08:57:37 2019

@author: MAlvarez
"""

import glob
import os

path_img=#path carpeta que contiene a las imagenes#
lista=glob.glob(path_img+'S1B*')#'S1B*' para que liste
    solamente a las del sensor Sentinel-1B
path_output=#path de la carpeta de salidas AUXILIARES. Su
    contenido sera eliminado cada vez que se procese un par de
    imagenes
path_output_final=#path de la carpeta de salidas
path_grafos=#path de la carpeta que contiene los grafos
path_gpt=#path ./gpt de SNAP
#####
#### Los siguientes archivos deben ser creados con la
    herramienta de procesamiento de grafos de SNAP
#### read1.xml
#### Split1.xml
#### TOPSAR-Split2.xml
#### Apply-Orbit-File1.xml
#### Apply-Orbit-File2.xml
#### Back-Geocoding.xml
#### Enhanced-Spectral-Diversity.xml
#### Coherence.xml
#### TOPSAR-Deburst.xml
```

```
#### Terrain-Correction.xml
#####

os.chdir(path\_img)
#Para todas las imagenes: i es la master y la que sigue la
  esclava

for i in lista:
    m=1
    j=1
    while (j < len(lista)):
        #Lee primera imagen
        input1=lista[i]
        target1=path_output+'R1/img1.dim'
        comando_r1='~path_gpt path_grafos/read1.xml -Pinput1=
            '+input1+' -t '+target1
        os.system(comando_r1)

        #Read 2nd image
        input2=input2=lista[i+m]
        target2=path_output+'R2/img2.dim'
        comando_r2='~path_gpt path_grafos/read1.xml -Pinput1=
            '+input2+' -t '+target2
        os.system(comando_r2)

        #Topsar-Split 1st image
        source1=target1
        target3=path_output+'TS1/TSimg1.dim'
        comando_ts1='~path_gpt path_grafos/TOPSAR-Split1.xml
            -Ssource1='+source1+' -t '+target3
        os.system(comando_ts1)

        #Topsar-Split 2nd image
        source1b=target2
        target4=path_output+'TS2/TSimg2.dim'
        comando_ts2='~path_gpt path_grafos/TOPSAR-Split2.xml
            -Ssource1b='+source1b+' -t '+target4
        os.system(comando_ts2)

        #Apply-Orbit-File 1st image
        source2=target3
        target5=path_output+'AOF1/AOFimg1.dim'
        comando_aof1='~path_gpt path_grafos/Apply-Orbit-File1
            .xml -Ssource2='+source2+' -t '+target5
        os.system(comando_aof1)

        #Apply-Orbit-File 2st image
        source3=target4
        target6=path_output+'AOF2/AOFimg2.dim'
        comando_aof2='~path_gpt path_grafos/Apply-Orbit-File2
```

```
.xml -Ssource3='+source3+' -t '+target6
os.system(comando_aof2)

#Back-Geocoding (corregistacion)
source4=target5
source5=target6
target7=path_output+'BG/BG.dim'
comando_bg='~path_gpt path_grafos/Back-Geocoding.xml
-Ssource4='+source4+' -Ssource5='+source5+' -t '+
target7
os.system(comando_bg)

#Enhanced-Spectral-Diversity (corregistacion)
source6=target7
target8=path_output+'ESD/ESD.dim'
comando_esd='~path_gpt path_grafos/Enhanced-Spectral-
Diversity.xml -Ssource6='+source6+' -t '+target8
os.system(comando_esd)

#Coherence map
source7=target8
target9=path_output+'COH/COH.dim'
comando_coh='~path_gpt path_grafos/Coherence.xml -
Ssource7='+source7+' -t '+target9
os.system(comando_coh)

#Tops Deburst
source8=target9
target10=path_output+'TD/TD.dim'
comando_td='~path_gpt path_grafos/TOPSAR-Deburst.xml
-Ssource8='+source8+' -t '+target10
os.system(comando_td)

#Terrain_correction

source9=target10
data1=input1[:]#intervalo [a:b] en el que esta la
fecha de las imagenes
data2=input2[:]#intervalo [a:b] en el que esta la
fecha de las imagenes

if data1[4:5] == '01':
    month1='Jan'
elif data1[4:5] == '02':
    month1='Feb'
elif data1[4:5] == '03':
    month1='Mar'
elif data1[4:5] == '04':
    month1='Apr'
elif data1[4:5] == '05':
```

```
        month1='May'
elif data1[4:5] == '06':
    month1='Jun'
elif data1[4:5] == '07':
    month1='Jul'
elif data1[4:5] == '08':
    month1='Aug'
elif data1[4:5] == '09':
    month1='Sep'
elif data1[4:5] == '10':
    month1='Oct'
elif data1[4:5] == '11':
    month1='Nov'
elif data1[4:5] == '12':
    month1='Dec'

if data2[4:6] == '01':
    month2='Jan'
elif data2[4:6] == '02':
    month2='Feb'
elif data2[4:6] == '03':
    month2='Mar'
elif data2[4:6] == '04':
    month2='Apr'
elif data2[4:6] == '05':
    month2='May'
elif data2[4:6] == '06':
    month2='Jun'
elif data2[4:6] == '07':
    month2='Jul'
elif data2[4:6] == '08':
    month2='Aug'
elif data2[4:6] == '09':
    month2='Sep'
elif data2[4:6] == '10':
    month2='Oct'
elif data2[4:6] == '11':
    month2='Nov'
elif data2[4:6] == '12':
    month2='Dec'

#Bands
bands='coh_IW2_VV_'+data1[6:8]+month1+data1[0:4]+'_'+
    data2[6:8]+month2+data2[0:4]+','+'coh_IW2_VH_'+
    data1[6:8]+month1+data1[0:4]+'_'+data2[6:8]+month2
    +data2[0:4]
output_final=path_output_final+'S1B_IW_SLC__1SDV_'+
    data1+'_'+data2+'_Orb_Stack_Coh_Deb_TC.dim'

-Ssource9=path_grafos/TD/TD.dim
```

```
comand_tc='path_gpt path_grafos/Terrain-Correction.  
xml -Ssource9='+source9+' -Pbands='+bands+' -t '+  
output_final  
  
#borra todos los pasos intermedios o auxiliares  
contenidos en la carpeta path_output  
borrar='rm -fr '+path_output  
os.system(borrar)  
j=j+1
```

ANEXO C

Estadística de diferencias entre clases por fechas

Tabla C.1: Diferencias entre clases - Coh VH

Fecha	Shapiro-Wilks p-valor	Levene p-valor	Fligner p-valor	Condición (Tabla 4.8)	Diferencias
0701_1901	4,000E-04	-	1,896E-07	c)	Iluc-mix; Iluc-nat; mix-nat: Sin Superposición de cinturas
1901_3101	2,647E-05	-	3,588E-04	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
3101_1202	2,029E-06	-	2,365E-01	d)	Iluc-mix TRUE; Iluc-nat FALSE; mix-nat FALSE
1202_2402	5,977E-04	-	2,026E-04	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
2402_0803	1,244E-03	-	8,435E-04	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
0803_2003	7,478E-02	2,323E-03	-	b)	Iluc-mix; mix-nat: Sin Superposición de cinturas Iluc-nat: Con Superposición de cinturas
2003_0104	3,516E-06	-	7,628E-05	c)	Iluc-mix; Iluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0104_1304	4,910E-03	-	4,346E-02	b)	Iluc-mix; mix-nat: Sin Superposición de cinturas Iluc-nat: Con Superposición de cinturas
1304_2504	1,298E-05	-	3,131E-03	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
2504_0705	1,650E-09	-	1,280E-01	d)	Iluc-mix FALSE; Iluc-nat FALSE; mix-nat FALSE
0705_1905	1,872E-04	-	6,999E-01	d)	Iluc-mix TRUE; Iluc-nat FALSE; mix-nat TRUE
1905_3105	6,173E-01	8,667E-03	-	b)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
3105_1206	2,865E-04	-	1,624E-02	c)	Iluc-mix; mix-nat: Con Superposición de cinturas Iluc-nat: Sin Superposición de cinturas
1206_2406	3,487E-01	2,067E-04	-	b)	Iluc-mix; Iluc-nat; mix-nat: Sin Superposición de cinturas
2406_0607	3,929E-01	1,802E-02	-	b)	Iluc-mix; Iluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0607_1807	7,084E-03	-	4,878E-02	c)	Iluc-mix; Iluc-nat; mix-nat: Sin Superposición de cinturas
1807_3007	1,400E-06	-	1,158E-02	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
3007_1108	6,144E-05	-	3,927E-10	c)	Iluc-mix; Iluc-nat; mix-nat: Sin Superposición de cinturas
1108_2308	1,969E-02	-	1,339E-09	c)	Iluc-mix; Iluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
2308_0409	5,117E-03	-	1,535E-01	d)	Iluc-mix FALSE; Iluc-nat FALSE; mix-nat FALSE

0409_1609	2,230E-02	-	5,119E-03	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
1609_2809	1,185E-04	-	9,744E-01	d)	Iluc-mix TRUE; Iluc-nat TRUE; mix-nat FALSE
2809_1010	2,246E-07	-	7,421E-02	d)	Iluc-mix FALSE; Iluc-nat FALSE; mix-nat TRUE
1010_2210	3,080E-03	-	3,092E-04	c)	Iluc-mix; mix-nat: Sin Superposición de cinturas Iluc-nat: Con Superposición de cinturas
2210_0311	1,061E-06	-	5,086E-05	c)	Iluc-mix; Iluc-nat; mix-nat: Sin Superposición de cinturas
0311_1511	1,523E-05	-	2,339E-04	c)	Iluc-mix; mix-nat: Con Superposición de cinturas Iluc-nat: Sin Superposición de cinturas
1511_2711	4,132E-12	-	1,800E-03	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
2711_0912	5,289E-04	-	8,908E-04	c)	Iluc-mix; mix-nat: Con Superposición de cinturas Iluc-nat: Sin Superposición de cinturas
0912_2112	2,496E-05	-	7,507E-02	d)	Iluc-mix FALSE; Iluc-nat FALSE; mix-nat FALSE

Tabla C.2: Diferencias entre clases - Coh VV

Fecha	Shapiro-Wilks p-valor	Levene p-valor	Fligner p-valor	Condición (Tabla 4.8)	Diferencias
0701_1901	3,286E-03	-	7,838E-04	c)	Iluc-mix; Iluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1901_3101	4,297E-08	-	3,946E-08	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
3101_1202	5,767E-08	-	3,273E-02	c)	Iluc-nat; mix-nat: Sin Superposición de cinturas Iluc-mix: Con Superposición de cinturas
1202_2402	2,657E-08	-	8,764E-03	c)	Iluc-mix; mix-nat: Sin Superposición de cinturas Iluc-nat: Con Superposición de cinturas
2402_0803	5,240E-02	7,496E-01	-	a)	p-valor mix-Iluc: 2.47-07 nat-Iluc: 1.73-08 nat-mix: 9.94e-01
0803_2003	2,959E-05	-	4,894E-03	c)	Iluc-mix; Iluc-nat; mix-nat: Con Superposición de cinturas
2003_0104	1,080E-03	-	2,581E-01	d)	Iluc-mix FALSE; Iluc-nat TRUE; mix-nat TRUE
0104_1304	6,949E-06	-	1,820E-05	c)	Iluc-mix; mix-nat: Con Superposición de cinturas Iluc-nat: Sin Superposición de cinturas

1304_2504	5,606E-03	-	1,855E-09	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
2504_0705	1,556E-06	-	1,799E-02	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
0705_1905	3,483E-09	-	4,375E-04	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
1905_3105	1,045E-01	3,057E-03	-	b)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
3105_1206	4,087E-03	-	9,707E-04	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1206_2406	1,122E-06	-	8,133E-02	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat TRUE
2406_0607	1,744E-05	-	4,436E-02	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0607_1807	1,532E-07	-	6,992E-02	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat TRUE
1807_3007	5,783E-04	-	3,645E-07	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
3007_1108	2,678E-01	4,740E-17	-	b)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1108_2308	2,363E-02	-	2,020E-03	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
2308_0409	4,999E-10	-	2,130E-01	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat FALSE
0409_1609	1,501E-05	-	5,344E-02	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat FALSE
1609_2809	6,475E-02	2,339E-17	-	b)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
2809_1010	8,365E-05	-	5,025E-01	d)	lluc-mix FALSE; lluc-nat TRUE; mix-nat FALSE
1010_2210	1,268E-01	7,837E-05	-	b)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
2210_0311	3,374E-05	-	2,495E-01	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat TRUE
0311_1511	3,208E-08	-	5,796E-01	d)	lluc-mix FALSE; lluc-nat TRUE; mix-nat TRUE
1511_2711	6,530E-11	-	5,620E-07	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
2711_0912	5,323E-10	-	1,197E-03	c)	mix-nat: Sin Superposición de cinturas lluc-nat; lluc-mix: Con Superposición de cinturas

0912_2112	1,105E-05	-	9,106E-01	d)	lluc-mix TRUE; lluc-nat FALSE; mix-nat FALSE
-----------	-----------	---	-----------	----	--

Tabla C.3: Diferencias entre clases - CR VH

Fecha	Shapiro-Wilks p-valor	Levene p-valor	Fligner p-valor	Condición (Tabla 4.8)	Diferencias
0701	3,346E-02	-	4,970E-06	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
1901	5,171E-02	2,052E-02	-	b)	lluc-mix; lluc-nat: Con Superposición de cinturas mix-nat: Sin Superposición de cinturas
3101	7,046E-02	2,278E-05	-	b)	lluc-mix; lluc-nat: Con Superposición de cinturas mix-nat: Sin Superposición de cinturas
1202	2,201E-03	-	1,416E-03	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
2402	3,119E-01	1,067E-02	-	b)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
0803	7,121E-02	8,951E-03	-	b)	lluc-mix; lluc-nat: Con Superposición de cinturas mix-nat: Sin Superposición de cinturas
2003	3,570E-01	1,234E-03	-	b)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
0104	6,397E-01	3,074E-04	-	b)	lluc-mix; lluc-nat: Con Superposición de cinturas mix-nat: Sin Superposición de cinturas
1304	3,485E-06	-	2,658E-04	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
2504	3,712E-04	-	6,594E-02	d)	lluc-mix FALSE; lluc-nat TRUE; mix-nat TRUE
0705	6,534E-05	-	1,168E-04	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
1905	8,755E-03	-	3,440E-03	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
3105	5,519E-02	3,637E-06	-	b)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas

1206	1,023E-02	-	1,147E-05	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
2406	4,009E-01	1,212E-01	-	a)	p-valor mix-lluc 9.99e-02 nat-lluc 3.23e-02 nat-mix 1.62e-05
0607	6,915E-01	1,151E-05	-	b)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
1807	1,744E-03	-	6,199E-02	d)	lluc-mix FALSE; lluc-nat TRUE; mix-nat TRUE
3007	7,065E-01	4,466E-01	-	a)	p-valor mix-lluc 6.82e-01 nat-lluc 2.72e-06 nat-mix 7.24e-08
1108	2,310E-06	-	1,100E-03	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
2308	4,316E-04	-	9,406E-11	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
0409	9,694E-04	-	2,857E-04	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
1609	2,258E-01	3,663E-01	-	a)	P-valor mix-lluc 7.10e-02 nat-lluc 9.45e-02 nat-mix 5.18e-05
2809	5,626E-07	-	3,085E-06	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
1010	9,418E-01	1,613E-05	-	b)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
2210	5,193E-02	4,838E-02	-	b)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
0311	7,481E-05	-	8,486E-03	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
1511	4,162E-03	-	3,627E-02	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
2711	4,172E-05	-	3,930E-03	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas

0912	1,094E-01	6,043E-05	-	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
2112	6,949E-04	-	2,159E-01	d)	lluc-mix FALSE; lluc-nat TRUE; mix-nat TRUE

Tabla C.4: Diferencias entre clases - CR VV

Fecha	Shapiro-Wilks p-valor	Levene p-valor	Fligner p-valor	Condición (Tabla 4.8)	Diferencias
0701	8,333E-03	-	6,875E-04	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
1901	1,551E-01	5,758E-06	-	b)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
3101	3,054E-05	-	1,454E-01	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat TRUE
1202	2,505E-02	-	6,106E-04	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
2402	1,395E-02	-	1,621E-01	c)	lluc-mix TRUE; lluc-nat FALSE; mix-nat TRUE
0803	2,317E-03	-	2,585E-03	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
2003	5,200E-01	1,120E-01	-	a)	p-valor mix-lluc 2.41e-03 nat-lluc 4.17e-03 nat-mix 3.35e-10
0104	9,545E-01	5,621E-09	-	b)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
1304	1,976E-01	-	7,340E-08	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
2504	1,766E-03	-	1,529E-08	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
0705	3,712E-02	-	4,675E-03	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
1905	1,360E-02	-	8,418E-04	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas

3105	3,580E-02	-	1,098E-03	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
1206	3,195E-02	-	3,977E-06	c)	lluc-mix; lluc-nat: Con Superposición de cinturas mix-nat: Sin Superposición de cinturas
2406	5,497E-02	4,373E-03	-	b)	lluc-mix; lluc-nat: Con Superposición de cinturas mix-nat: Sin Superposición de cinturas
0607	7,254E-02	1,277E-02	-	b)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
1807	4,282E-02	-	6,708E-05	c)	lluc-mix; mix-nat: Sin Superposición de cinturas lluc-nat: Con Superposición de cinturas
3007	1,843E-04	-	3,630E-04	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
1108	2,953E-05	-	6,732E-04	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
2308	4,076E-02	-	2,641E-03	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
0409	4,876E-02	-	1,468E-04	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
1609	2,606E-01	6,577E-02	-	a)	p-valor mix-lluc 0,456 nat-lluc 4.06e-03 nat-mix 4.81e-05
2809	6,117E-03	-	1,099E-03	c)	lluc-nat; mix-nat: Sin Superposición de cinturas lluc-mix: Con Superposición de cinturas
1010	1,644E-01	2,983E-07	-	b)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
2210	3,214E-03	-	2,226E-03	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
0311	1,077E-01	2,081E-03	-	b)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
1511	3,039E-01	2,215E-01	-	a)	p-valor mix-lluc 0,247 nat-lluc 6.06e-05 nat-mix 3.22e-08
2711	2,296E-03	-	2,753E-03	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas

0912	1,480E-01	3,946E-03	-	b)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
2112	5,764E-02	7,985E-03	-	b)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas

Tabla C.5: Diferencias entre clases - NDVI

Fecha	Shapiro-Wilks p-valor	Levene p-valor	Fligner p-valor	Condición (Tabla 4.8)	Diferencias
0701_1901	2,217E-15	-	5,964E-07	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1901_3101	1,210E-06	-	2,742E-02	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
3101_1202	1,810E-03	-	5,634E-01	d)	lluc-mix TRUE; lluc-nat FALSE; mix-nat TRUE
1202_2402	4,269E-02	-	3,306E-02	c)	lluc-mix; lluc-nat; mix-nat: Con Superposición de cinturas
2402_0803	5,597E-08	-	4,905E-04	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0803_2003	5,867E-14	-	1,769E-04	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
2003_0104	1,789E-17	-	2,066E-04	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0104_1304	7,311E-19	-	4,568E-05	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1304_2504	4,181E-17	-	5,729E-05	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
2504_0705	8,087E-17	-	3,944E-06	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0705_1905	8,451E-15	-	1,584E-07	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1905_3105	4,909E-13	-	2,950E-07	c)	lluc-mix; mix-nat: Con Superposición de cinturas lluc-nat: Sin Superposición de cinturas

3105_1206	5,409E-08	-	5,461E-03	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1206_2406	2,473E-13	-	9,231E-05	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
2406_0607	2,256E-15	-	2,525E-05	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0607_1807	5,017E-08	-	1,146E-03	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1807_3007	8,161E-13	-	1,800E-07	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
3007_1108	1,797E-12	-	6,085E-05	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
1108_2308	5,231E-10	-	2,818E-05	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
2308_0409	1,035E-10	-	2,300E-06	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
0409_1609	2,963E-08	-	1,693E-05	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
1609_2809	1,766E-07	-	3,596E-04	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
2809_1010	5,394E-09	-	6,169E-01	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat FALSE
1010_2210	3,946E-11	-	9,528E-03	c)	lluc-mix; mix-nat: Con Superposición de cinturas lluc-nat: Sin Superposición de cinturas
2210_0311	1,361E-10	-	1,645E-02	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas
0311_1511	5,084E-04	-	1,689E-01	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat TRUE
1511_2711	4,398E-09	-	6,649E-02	d)	lluc-mix TRUE; lluc-nat TRUE; mix-nat FALSE
2711_0912	3,030E-10	-	1,634E-03	c)	lluc-mix; lluc-nat; mix-nat: Sin Superposición de cinturas
0912_2112	3,854E-13	-	1,408E-02	c)	lluc-mix; lluc-nat: Sin Superposición de cinturas mix-nat: Con Superposición de cinturas