

UNIVERSIDAD NACIONAL DE CATAMARCA
FACULTAD DE TECNOLOGÍA Y CIENCIAS APLICADAS
DOCTORADO EN AGRIMENSURA



TESIS DOCTORAL

*Cartografía de áreas agrícolas inundadas
ante un evento climático extremo
utilizando imágenes satelitales SAR*

Doctorando: Ing. Agrim. SILVIO DANIEL GRACIANI M.U. N° 041

Director: Dr. MARCO BROGIONI

Año 2022

A mi esposa Patricia y mi hijo Mauro,
a mis padres Hugo y Adela.

AGRADECIMIENTOS

A la Facultad de Tecnología y Ciencias Aplicadas de la Universidad Nacional de Catamarca, por haberme brindado la posibilidad de realizar mis estudios de Doctorado.

A las autoridades de la Facultad de Ingeniería y Ciencias Hídricas de la Universidad Nacional del Litoral, por su apoyo permanente para la culminación del curso de Doctorado.

Al Dr. Marco Brogioni, por sus conocimientos y el tiempo dedicado en su tarea como Director de Tesis, ofreciéndome siempre sus valiosos aportes y sugerencias en la ejecución del presente trabajo.

A mis colegas docentes de la Facultad de Ingeniería y Ciencias Hídricas de la Universidad Nacional del Litoral, por su valioso apoyo y colaboración.

Al Ing. Geógrafo Carlos Canoba por haberme transferido su pasión y conocimientos en la interpretación de imágenes satelitales.

Al Ing. Geógrafo Hugo Zingaretti por haberme infundido su vocación por la Agrimensura, despertando mi mayor respeto por esta profesión.

RESUMEN

El principal objetivo de esta investigación es contribuir a la determinación de las superficies inundadas, particularmente las que están cubiertas con vegetación, en áreas de llanura durante un evento climático extremo, a través de la utilización de imágenes satelitales Radar de Abertura Sintética (SAR). Por este motivo se analizan varios métodos de clasificación para evaluar sus performances y producir un algoritmo que pueda extraer las áreas inundadas. El caso de estudio es un sector de la cuenca superior del Arroyo Cululú, localizada en el Departamento Castellanos en la Provincia de Santa Fe - Argentina (31° 10' de latitud Sur y 61° 50' de longitud Oeste).

Para tal fin se compararon y validaron ocho algoritmos aplicados sobre imágenes SAR del satélite Sentinel 1B, banda C y polarización VV-VH. Para esto, se utilizaron los indicadores derivados de la aplicación de la matriz de error, obteniéndose un índice de fiabilidad global del 83,4% para el algoritmo seleccionado denominado Mixto. El mismo presenta como principales ventajas: simplicidad y rapidez, desde el punto de vista computacional; la explotación de los conjuntos de datos de observación de la tierra (Big Data EO); la fácil selección de umbrales y la capacidad para delimitar tanto las áreas rurales inundadas con agua "libre", sin obstrucciones, como las cubiertas por ciertos cultivos (tal el caso del maíz).

Por último, se puede indicar que el algoritmo permite generar los mapas temáticos de inundación a través de la aplicación de un procedimiento sencillo de cuatro pasos, que utiliza como insumo básico una imagen SAR de descarga gratuita y se ejecuta a través de un programa de acceso libre. Siendo, por lo tanto, recomendado para su utilización por parte de las diversas instituciones del estado provincial que intervienen ante tales situaciones de emergencia hídrica.

ABSTRACT

The main objective of this research is to contribute to the determination of flooded surfaces, particularly those covered with vegetation, in plain areas during an extreme climatic event, through the use of Synthetic Aperture Radar (SAR) satellite images. For this reason, several classification methods are analyzed to evaluate their performances and produce an algorithm that can extract the flooded areas. The case study is a sector of the upper basin of the Arroyo Cululú, located in the Castellanos Department in the Province of Santa Fe - Argentina (31° 10' South latitude and 61° 50' West longitude).

Eight algorithms applied to SAR images of the Sentinel 1B satellite, C band and VV-VH polarizations were validated and compared. To this end, the indicators derived from the application of the error matrix were used, obtaining a global reliability index of 83,4% for the selected algorithm called Mixed. It presents as main advantages: simplicity and speed, from the computational point of view; the exploitation of Earth observation data sets (Big Data EO); the easy selection of thresholds and the ability to delimit both rural areas flooded with "open" water, without obstructions, and those covered by certain crops (such as the case of corn cultivation).

Finally, it can be indicated that the algorithm allows the generation of the thematic flood maps through the application of a simple four-step procedure, which uses free open SAR data as a basic input and is executed through a freely available processing software. Being, therefore, recommended for use by the various institutions of the Provincial State that intervene in such situations of water emergency.

SOMMARIO

L'obiettivo principale di questa ricerca é di contribuire alla determinazione delle superfici allagate, in particolare quelle ricoperte da vegetazione, nelle zone di pianura durante un evento climatico estremo, attraverso l'uso di immagini satellitari SAR (Synthetic Aperture Radar). Per questo motivo vengono analizzati diversi metodi di classificazione per valutarne le prestazioni e produrre un algoritmo in grado di estrarre le aree allagate. Il caso di studio è un settore del bacino superiore di Arroyo Cululú, situato nel dipartimento di Castellanos nella provincia di Santa Fe - Argentina (31° 10' di latitudine sud e 61° 50' di longitudine ovest).

A tal fine, otto algoritmi differenti sono stati applicati alle immagini SAR del satellite Sentinel 1B, banda C e polarizzazioni VV-VH e i risultati convalidati e confrontati. Per questa analisi sono stati utilizzati gli indicatori derivati dall'applicazione della matrice di errore, ottenendo un indice di affidabilità globale del 83,4% per l'algoritmo migliore denominato Misto. Questo presenta come principali vantaggi: semplicità e velocità, dal punto di vista computazionale; lo sfruttamento dei set di dati di osservazione della Terra (Big Data EO); la facile selezione delle soglie e la possibilità di delimitare sia le aree rurali allagate da acqua "libera", senza ostacoli, sia quelle coperte da determinate colture (come nel caso della coltivazione del mais).

L'algoritmo consente la generazione delle mappe tematiche di alluvione attraverso l'applicazione di una semplice procedura in quattro fasi, che utilizza come input prodotti SAR ottenibili gratuitamente e viene eseguita tramite un programma disponibile gratuitamente online. Quindi consigliato per l'utilizzo da parte dei vari Enti dello Stato che intervengono in tali situazioni di emergenza idrica.

ÍNDICE DE CONTENIDOS

	Página
1. PRESENTACIÓN Y ANÁLISIS DEL PROBLEMA	1
1.1 INTRODUCCIÓN	1
1.2 OBJETIVOS	4
1.2.1 Objetivo General	4
1.2.2 Objetivos Específicos	4
1.3 ÁREA DE ESTUDIO	5
1.3.1 Ubicación	5
1.3.2 Características Climáticas	7
1.3.3 Características Geomorfológicas	9
1.3.4 Características de los Suelos	11
1.3.5 Características Hidrológicas	13
1.3.6 Características Topográficas	15
1.3.7 Características Productivas	18
1.3.8 Evento Climático Extremo	19
2. ESTADO DEL ARTE	23
2.1 MAPAS DE INUNDACIÓN DESDE IMÁGENES SAR	23
2.2 MAPAS DE INUNDACIÓN DE HUMEDALES DESDE IMÁGENES SAR	29
2.3 MÉTODOS PARA DETECTAR VEGETACIÓN INUNDADA	31
2.4 MÉTODOS PARA DETECTAR SUPERFICIES ABIERTAS INUNDADAS	39
2.5 VALIDACIÓN DE LA INFORMACIÓN DERIVADA DE IMÁGENES SAR	46
2.6 RESUMEN DE LOS MÉTODOS DE CLASIFICACIÓN	49
3. FUNDAMENTACIÓN TEÓRICA	52
3.1 INTERACCIÓN ENTRE LA SEÑAL SAR y LOS CUERPOS DE AGUA	52
3.2 INTERACCIÓN ENTRE LA SEÑAL SAR y LA VEGET. NO INUNDADA	53

3.3 INTERACCIÓN ENTRE LA SEÑAL SAR y LA VEGETACIÓN INUNDADA	54
3.4 INTERACCIÓN ENTRE LA SEÑAL SAR y CIERTOS CULTIVOS	55
4. MATERIALES Y MÉTODO	58
4.1 MATERIALES	58
4.1.1 Datos de campo	58
4.1.2 Datos Auxiliares	61
4.1.3 Imágenes Ópticas	62
4.1.4 Imágenes SAR	63
4.2 MÉTODO	64
4.2.1 PRE-PROCESAMIENTO	65
4.2.2 PROCESAMIENTO	67
4.2.3 MÉTODOS DE CLASIFICACIÓN APLICADOS	69
4.2.3.1 Umbral Manual	69
4.2.3.2 Detección de Cambios	70
4.2.3.3 PolSAR	72
4.2.3.4 InSAR	74
5. DESCRIPCIÓN DE HIPÓTESIS	75
6. RESULTADOS	76
6.1 PROCESAMIENTO	76
6.1.1 Imagen Óptica	76
6.1.2 Imagen SAR	78
6.2 MÉTODOS DE CLASIFICACIÓN APLICADOS	79
6.2.1 Umbral Manual	79
6.2.2 Detección de Cambios	87
6.2.2.1 Índices de Inundación	87
6.2.2.2 Cociente de bandas	95
6.2.3 PolSAR	100

6.2.3.1 Parámetros Polarimétricos (H, α y A)	100
6.2.3.2 Clasificación Polarimétrica No Supervisada	105
6.2.4 InSAR	108
7. ANÁLISIS DE LOS RESULTADOS	110
7.1 COMPARACIÓN DE LOS MÉTODOS DE CLASIFICACIÓN	110
7.2 VALIDACIÓN DE LOS MÉTODOS DE CLASIFICACIÓN	115
8. CONCLUSIONES	123
REFERENCIAS BIBLIOGRÁFICAS	125
ANEXOS	134
I. PRINCIPALES VENTAJAS Y DESVENTAJAS DE LOS MÉTODOS DE CLASIFICACIÓN SUPERVISADOS Y NO SUPERVISADOS	134
II. SUPERFICIES INUNDADAS DE LAS CUBETAS DETERMINADAS POR LOS MÉTODOS DE CLASIFICACIÓN	138
III. MATRICES DE ERROR DE LOS MÉTODOS UTILIZADOS	147
IV. CARTOGRAFÍAS TEMÁTICAS DE LAS SUPERFICIES INUNDADAS	156

ÍNDICE DE FIGURAS

	Página
1. Localización del área de estudio en la República Argentina – Provincia de Santa Fe - Departamento Castellanos.	5
2. Área de estudio incluye once distritos del Dep. Castellanos – Prov. de Santa Fe.	6
3. Ubicación de la localidad de Vila en relación a las ciudades más – importantes aledañas al área de interés.	6
4. Rutas nacionales, provinciales y localidades del área de estudio.	7
5. Ubicación de la Cca. del arroyo Cululú en el centro-oeste de la Prov. de Santa Fe (izq.) y localización del área de estudio en dicha Cca. (der.).	10
6. Distribución del Índice de product. en función de las clases de suelo.	13
7. Red de drenaje natural y artificial de la cuenca del Arroyo Cululú.	14
8. MDT con la cuenca del Arroyo Cululú superpuesta.	15
9. Perfiles topográficos sobre el área de estudio.	16
10. Perfil topográfico con sentido Oeste-Este (arriba) y el mismo interpolado Interpolado (abajo).	16
11. Perfiles topográficos atravesando las cubetas 1 y 2 del área de estudio.	17
12. Perfil topográfico con sentido Sur-Norte (arriba) y el mismo interpolado (abajo).	18
13. Precipitación acumulada en mm (izq.) y anomalía de precipitación en mm (der.) en enero de 2017.	19
14. Lotes agrícolas del área de estudio completamente inundados.	21
15. Lotes de maíz inundados en el área de interés que se perdieron.	21
16. Tambo inundado localizado en el área de interés.	22
17. Otro tambo inundado en el área de estudio.	22
18. Calles y plaza de la localidad de Vila inundados.	22
19. Métodos de clasificación supervisado y no supervisado y el número de aplicaciones para la extracción de la vegetación inundada en casos de estudio seleccionados.	32
20. Métodos de clasificación basados en Distancia y el número de ocurrencias para la extracción de la vegetación inundada en casos de estudio seleccionados.	33
21. Métodos de clasificación supervisado de Aprendizaje Automático y el número de ocurrencias para la extracción de la vegetación inundada en casos de estudio seleccionados.	36

22.	Métodos de clasificación supervisado y no supervisado y el número de ocurrencias para la determinación de áreas abiertas inundadas en diversos casos de estudio.	40
23.	Estructura de la matriz de error o de confusión.	47
24.	Dispersión especular en el agua (izq.) y difusa desde el suelo (der.).	53
25.	Dispersión de la señal SAR desde distintos estratos de la vegetación en función de la longitud de onda empleada (Banda).	54
26.	Dispersión difusa desde el suelo no inundado (izq.) y de doble rebote (agua - tronco) en el inundado (der.).	55
27.	Dispersión dominante en un cultivo: de volumen cuando no está inundado (izq.), doble rebote lo está parcialmente (centro) y especular completamente inundado (der.).	56
28.	Cultivo de maíz en diversas situaciones: no inundado (izq.), parcialmente anegado (centro) y completamente cubierto por el agua (der.).	57
29.	Localización de los puntos de muestreo en el área de estudio (amarillo) superpuestos a la imagen Sentinel 2 (RGB-118a5) del 10/01/2017.	58
30.	Lotes completamente inundados, puntos 4 (izq.) y 16 (der.).	60
31.	Lotes con maíces inundados, puntos 2 (izq.) y 15 (der.).	60
32.	Lote con charcos de agua entre los surcos de soja, punto 13.	61
33.	Lotes con charcos de agua en sorgo (pto. 8 izq.) y en soja (pto. 19 der.)	61
34.	Imagen SAR del satélite Sentinel 1B en modo IW.	64
35.	Método para la determinación del área inundada, a la derecha en color verde se observa la descripción de las etapas.	65
36.	Procedimiento aplicado a las imágenes SAR Sentinel 1B (GRD y SLC).	67
37.	Plano H / Alfa.	73
38.	Composición color RGB-118a5 (izq.) e índice de vegetación NDVI (der.) de la imagen óptica Sentinel 2 adquirida el 11/12/2016.	76
39.	RGB-118a5 (izq.) e índice de agua NDWI (der.) de la imagen Sentinel 2 del 10/01/2017.	77
40.	Cubetas o bajos digitalizados por interpretación visual de la imagen. RGB-118a5 (izquierda) y del índice de agua NDWI (derecha) de la imagen Sentinel 2 del 10/01/2017.	78
41.	Imagen Sigma0 VV se observan las áreas inundadas en la cubeta 1 en negro cuando se produce disper. espec. y en blanco para dob. rebote.	80
42.	Imagen Sigma0 VH se aprecia en color negro la dispersión especular.	80

43.	Imagen del cociente $\text{Sigma0 VV} / \text{Sigma0 VH}$, se observan en color blanco áreas con dispersión de doble rebote y especular; y en negro las que tienen solo especular.	81
44.	La composición color RGB_VV-VH-VV/VH muestra en color negro y azul la dispersión especular y en magenta la de doble rebote.	82
45.	Umbral aplicado a la Imagen Sigma0 VV para diferenciar las áreas inundadas donde se produce dispersión de doble rebote.	83
46.	Umbral aplicado a $\sigma_0 \text{ VH}$ para diferenciar áreas inundadas con dispersión especular.	83
47.	Umbral aplicado al cociente VV/VH para diferenciar áreas inundadas con dispersión de doble rebote.	84
48.	Imagen binaria resultante del umbral aplicado a Sigma0 VV , en azul las áreas anegadas en donde se produce dispersión de doble rebote.	85
49.	Imagen binaria derivada del umbral aplicado a Sigma0 VH , en azul las áreas anegadas con dispersión especular.	85
50.	Imagen binaria obtenida del umbral aplicado al cociente $\sigma_0 \text{ VV} / \sigma_0 \text{ VH}$ en azul se aprecian las áreas anegadas que son resaltadas por la disper. de doble rebote agua-tallo.	86
51.	Superficie total inundada (azul) el día 14/01/2017 según el algoritmo de clasificación supervisado denominado Umbral Manual.	87
52.	Imagen del índice NDFI_{VH} , se observa en blanco la disper. especular.	88
53.	Imagen del índice NDFVI_{VV} , se ve en blanco la dispersión doble rebote.	89
54.	Imagen resultante de la suma de las imágenes binarias de los índices $\text{NDFI}_{\text{VV+VH}}$, en azul las áreas anegadas con dispersión especular.	90
55.	Imagen binaria del umbral aplicado al índice NDFVI_{VV} , en azul las áreas anegadas con dispersión de doble rebote.	90
56.	Superficie total inundada (azul) determinada por el algoritmo supervisado de detección de cambios utilizando índices de inundación NDFI e NDFVI (primer caso).	91
57.	Imagen del índice NDFI_{VV} , se observa en blanco la disper. especular.	92
58.	Imagen del índice NDFVI_{VV} , se ve en color blanco la disper. doble rebote	92
59.	Imagen del umb. aplicado al NDFI_{VV} en azul áreas anegadas con espec.	93
60.	Imagen del umb. aplicado al índice NDFVI_{VV} en azul las áreas inundadas con dispersión doble rebote entre el agua y los tallos de las plantas.	94

61.	Super. total inundada (azul) el día 14/01/2017 determinada por el algoritmo de detección de cambios utilizando índices NDFI e NDFVI (segundo caso).	94
62.	Imágenes de los Cocientes VH (arriba) y VV (abajo), en ambas se observan en blanco la dispersión especular del agua y en negro la de doble rebote agua-tallo.	95
63.	Superficie inundada (azul) el día 14/01/2017 con dispersión especular obtenida de la suma de ambos Cocientes (VV + VH) de las imágenes en formato GRD.	96
64.	Superficie inundada (azul) con dispersión de doble rebote obtenida del Cociente VV de las imágenes en formato GRD.	97
65.	Superficie total inundada (azul) derivada de los Cocientes VH y VV formato GRD.	97
66.	Composición color RGB_CocienteVV - CocienteVH - CocienteVH, se observan en colores blanco y cian las áreas inundadas con dispersión especular.	98
67.	Superficie inundada (azul) el día 14/01/2017 con dispersión especular derivada de la suma de ambos Cocientes (VV + VH) de las imágenes en formato SLC.	
68.	Superficie inundada (azul) con dispersión doble rebote obtenida del Cociente VV.	99
69.	Superficie total inundada (azul) derivada de los Cocientes VH y VV formato SLC.	100
70.	Imagen del parámetro polarimétrico Alfa (α) en donde se observan en blanco las áreas con dispersión especular y en negro con doble rebote.	101
71.	Imagen del parámetro Entropía (H) derivado de la imagen del 14/01/2017.	101
72.	Imagen del parámetro polarimétrico Anisotropía (A) en donde se aprecian en color blanco las áreas con dispersión de doble rebote y en negro con especular.	102
73.	Superficie inundada (azul) derivada de la dispersión especular en el agua "libre".	103
74.	Superficie inundada (azul) determinada de la dispersión de doble rebote.	104
75.	Superficie total inundada (azul) obtenida de la clasificación supervisada de los parámetros polarimétricos Alfa (α) y Anisotropía (A).	105

76.	Clasificación polarimétrica H-Alpha Wishart, indicando color anaranjado la dispersión especular (clase 3) y en azul la de doble rebote (clase 7).	106
77.	Superficie inundada (azul) con interacción especular (clase 3).	106
78.	Superficie inundada (azul) con dispersión de doble rebote (clase 7).	107
79.	Super. total inundada (azul) derivada de la clasificación H-Alpha Wishart.	107
80.	Histograma de la imagen de Coherencia v_v mostrando un valor medio de 0,27.	109
81.	Imagen de Coherencia v_v mostrando valores bajos (grises) en las áreas rurales y valores altos (blanco) en las áreas urbanas.	109
82.	Cubetas inundadas digitalizadas sobre la imagen óptica RGB-118a5.	110
83.	Áreas de control (rojo) para ejecutar la matriz de error de cada algoritmo aplicado, superpuestas a la imagen óptica Sentinel 2 RGB-118a5.	116
84.	Cartografía temática de superficies inundadas en el área de estudio.	121
85.	Superposición del parcelario rural a la cartografía temática de áreas inundadas en un sector del área de estudio.	122

ÍNDICE DE TABLAS

Página

1.	Estaciones meteorológicas con récord diario de precipitación el 03/01/17.	20
2.	Precipitaciones de referencia durante el período 22/12/16 al 13/01/17.	20
3.	Puntos de muestreo tomados en el área de estudio en enero de 2017.	59
4.	Día de adquisición y caract. de las imágenes ópticas - Sentinel 2A .	62
5.	Día de adquisición y caract. de las imágenes ópticas - Landsat 8.	62
6.	Día de adquisición y caract. de las imágenes ópticas - Sentinel 3A.	63
7.	Día de adquisición y caract. de las imágenes SAR - Sentinel 1B.	63
8.	Superficies inundadas en la cubeta 1 derivadas de los mecanismos de dispersión especular y de doble rebote, determinadas por los algoritmos.	111
9.	Superficies inundadas en la cubeta 2 derivadas de los mecanismos de dispersión especular y de doble rebote, determinadas por los algoritmos.	111
10.	Superficie total inundada en ambas cubetas detectada a partir de la dispersión especular y de doble rebote por los distintos algoritmos y el porcentaje (%) correspondiente.	112
11.	Superficie total inundada en cada cubeta determinada por los algoritmos.	113
12.	Porcentaje de la super. inundada en cada cubeta derivado de los algoritmos.	113
13.	Orden decreciente del porcentaje promedio de inundación expresado por cada algoritmo en las dos cubetas consideradas.	114
14.	Superficies inundada y no inundada determinadas por los algoritmos en el área de estudio dispuestas en orden decreciente.	115
15.	Matriz de error del algoritmo NDWI.	116
16.	Matriz de error del algoritmo Mixto.	117
17.	Matriz de error del algoritmo Umbral Manual	117
18.	Matriz de error del algoritmo NDFI NDFVI.	117
19.	Matriz de error del algoritmo NDFI NDFVI Serie.	117
20.	Matriz de error del algoritmo Cociente VV/VH - GRD.	118
21.	Matriz de error del algoritmo Cociente VV/VH - SLC.	118
22.	Matriz de error del algoritmo H - Alfa.	118
23.	Matriz de error del algoritmo H - Alfa - Clasif.	118
24.	Errores de Omisión y Comisión de cada algoritmo en orden creciente.	119
25.	Índices de Fiabilidad global (%) y Kappa de cada algoritmo empleado ordenados de manera decreciente según el primero.	120
26.	Métodos de clasificación para detectar Vegetación Inundada.	134
27.	Métodos de clasificación para detectar Superficies Abiertas Inundadas	135

1. PRESENTACIÓN Y ANÁLISIS DEL PROBLEMA

1.1 INTRODUCCIÓN

El incremento de los eventos climáticos extremos ha demostrado una demanda de mapas de inundaciones casi en tiempo real derivados de datos de Teledetección. La cartografía de tales eventos es vital para respaldar las decisiones de rescate y para facilitar la evaluación rápida de pérdidas y daños a la propiedad privada. La capacidad de los sensores SAR para penetrar la capa de nubes, con las mejoras en la resolución espacial y temporal de los conjuntos de datos de observación de la tierra (Big Data EO) disponibles gratuitamente, demuestran el papel clave que el SAR tiene en la gestión de inundaciones.

Las proyecciones de cambio climático prevén un número creciente de dichos eventos climáticos con ocurrencia de precipitaciones intensas que consecuentemente producirán inundaciones. Un mapeo preciso y rápido de estos fenómenos es un componente clave de los planes de gestión de emergencias y reducción del riesgo de desastres. Los Big Data EO, como los adquiridos por el programa Copernicus de la Agencia Espacial Europea (ESA), brindan oportunidades sin precedentes para detectar cambios y evaluar impactos en caso de desastres.

Las técnicas de Teledetección por microondas tienen una excelente penetración a través de la atmósfera y, por lo tanto, pueden proporcionar una medición más eficiente. La utilización de radiómetros (sensores de microondas pasivos), para detectar la fracción de agua, tiene la ventaja de poseer una alta resolución temporal (diaria), sin embargo, presenta una baja resolución espacial (~ 25 km), lo cual permite el mapeo de inundaciones a escala global o regional (< 1/10.000.000), pero los inhabilita para delimitar inundaciones a escala local (> 1/100.000). En el caso de los sensores activos de microondas, Radar de Apertura Sintética (SAR), los mismos pueden utilizarse para cartografiar la inundación en casi cualquier condición meteorológica con una resolución espacial alta (> 30 m). Además, por ser un sensor activo, el SAR también puede tomar imágenes durante la noche.

A diferencia de los sensores ópticos, el SAR proporciona mediciones válidas a través de la cobertura de nubes con alta resolución y frecuencia de muestreo

creciente a partir de la existencia de múltiples misiones satelitales (SAOCOM 1 - banda L, ALOS 2 - banda L, SENTINEL 1 - banda C, RADARSAT 2 - banda C, RISAT 1 - banda C, TERRASAR - banda X, COSMOS SKYMED - banda X, KOMPSAT 5 - banda X, PAZ - banda X, HUAN JING 1C - banda S, etc.). Sin embargo, no todos ellos proporcionan imágenes de acceso gratuito que posibilitan su uso por parte de instituciones del estado provincial y/o nacional encargadas del monitoreo y la demarcación de las áreas inundadas durante los eventos climáticos extremos. Por lo tanto, en este trabajo se priorizó el empleo de datos SAR de descarga libre, tal el caso del SENTINEL 1 de la Agencia Espacial Europea (ESA).

En la actualidad, la automatización para el mapeo de inundaciones en superficies abiertas se ha logrado con una precisión aceptable a partir del uso de los datos de observación de la Tierra (X. Shen *et al.*, 2019) [1]. Esto se debe a que los métodos empleados para determinar las áreas abiertas son simples y confiables dado que se basan en la detección del mecanismo de dispersión especular que se produce en la superficie del agua. Sin embargo, aún no son satisfactorios para extraer la vegetación inundada (VI) porque tales métodos no son aplicables y no funcionan con la VI porque se producen otros mecanismos de dispersión más complejos (doble rebote y volumen). Por lo tanto, es necesario avanzar hacia el desarrollo o adaptación de métodos específicos puesto que no considerar la VI puede conducir a una subestimación del alcance de una inundación provocando un mayor riesgo para las personas y daños a sus propiedades. Además, las inundaciones afectan a las zonas agrícolas de todo el mundo, lo que implica enormes pérdidas económicas.

La principal ventaja de la tecnología SAR para detectar la VI es su capacidad para penetrar el dosel de la vegetación hasta encontrar la presencia de agua. Los valores de retrodispersión SAR (Backscattering) pueden aumentar significativamente al interceptar la señal el agua debajo de la vegetación debido a la interacción de doble rebote entre la superficie reflectante especular del agua y las estructuras verticales de la vegetación, tales como troncos y tallos (L. Pulvirenti *et al.*, 2013) [2].

Aunque existen claras ventajas en el uso de los datos SAR para la determinación de la VI, aún persisten desafíos con respecto al análisis de las imágenes SAR y su interpretación, así como ciertas limitaciones para el correcto mapeo de la VI. El speckle presente en todas las imágenes SAR, puede dar lugar a

incertidumbres en las mediciones y, en consecuencia, puede producir una disminución de la precisión de la clasificación. Además, la mayor retrodispersión causada por el doble rebote, no es siempre detectable dependiendo de los parámetros ambientales (por ejemplo, la biomasa sobre el suelo) y las características del sensor (longitud de onda, polarización, etc.). Finalmente, la intensidad de la retrodispersión de la VI puede ser similar a la proveniente de áreas urbanas y de áreas de suelo desnudo con alto contenido de humedad. Esto puede resultar en la confusión y la clasificación errónea de la VI (B. Chapman *et al.*, 2015 [3]; L. Pulvirenti *et al.*, 2016) [4].

El progreso técnico de los sistemas SAR y los avances en la tecnología informática han llevado al desarrollo de algoritmos adecuados para la extracción de la VI de las imágenes SAR en las últimas décadas. Por lo tanto, el objetivo de esta investigación es avanzar hacia la determinación de la extensión de la inundación, tanto en aguas abiertas, como, con vegetación inundada, empleando conjuntos de datos SAR satelitales multitemporales gratuitos (banda C y polarización doble VV y VH), con métodos de procesamiento rápidos y fáciles de aplicar en extensas áreas de llanura, tales como la correspondiente a Distritos o Departamentos Provinciales, a medida que se vuelven disponibles nuevos datos en otras bandas (S, L y P) y con polarización completa (HH, VV, VH y HV).

1.2. OBJETIVOS

1.2.1 Objetivo General

El objetivo general de esta investigación es identificar un método para determinar las superficies inundadas, abiertas y con vegetación, en áreas de llanura durante un evento climático extremo, a través de la utilización de imágenes satelitales Radar de Abertura Sintética (SAR), banda C polarización dual. El área de estudio es un sector de la cuenca superior del Arroyo Cululú en la Provincia de Santa Fe - Argentina.

1.2.2 Objetivos Específicos

1. Evaluar y comparar distintos métodos de procesamiento de imágenes SAR para cartografiar inundaciones en áreas de llanura.
2. Determinar lotes rurales inundados con cobertura vegetal agrícola, en los cuales el agua no sobrepasa el dosel vegetal.
3. Generar/adaptar un algoritmo que pueda ser incorporado como procedimiento operativo en las instituciones del estado provincial volcadas al manejo de los recursos naturales (aguas y suelos) y de la producción (agropecuaria).
4. Ejecutar mapas temáticos de inundación, a partir de la información elaborada que permitan interpretar su estado de situación en tiempo casi real a la obtención de las imágenes SAR.

1.3. ÁREA DE ESTUDIO

1.3.1 Ubicación

El área de estudio está ubicada en el centro-oeste de la provincia de Santa Fe, en el departamento Castellanos (Figura 1), se localiza en la parte alta de la cuenca del Arroyo Cululú presentando un relieve plano con numerosos bajos en forma de cubetas. La misma integra la región agrícola-ganadera e industrial de la Provincia, concentrando gran parte de la actividad del sector.

Específicamente el área de interés involucra 11 distritos del departamento Castellanos (Figura 2), en 7 de ellos se considera el 100% de su superficie, tal el caso de: Egusquiza, Presidente Roca, Bigand, Castellanos, San Antonio, Fidela y Vila. Y en los otros 4 distritos aproximadamente el 80% de su superficie, tratándose de los siguientes: Pueblo Marini, Bauer y Sigel, Ramona y Coronel Fraga. Esto se debe a que las imágenes utilizadas, ópticas y SAR, no llegan a cubrir la totalidad de los mismos.

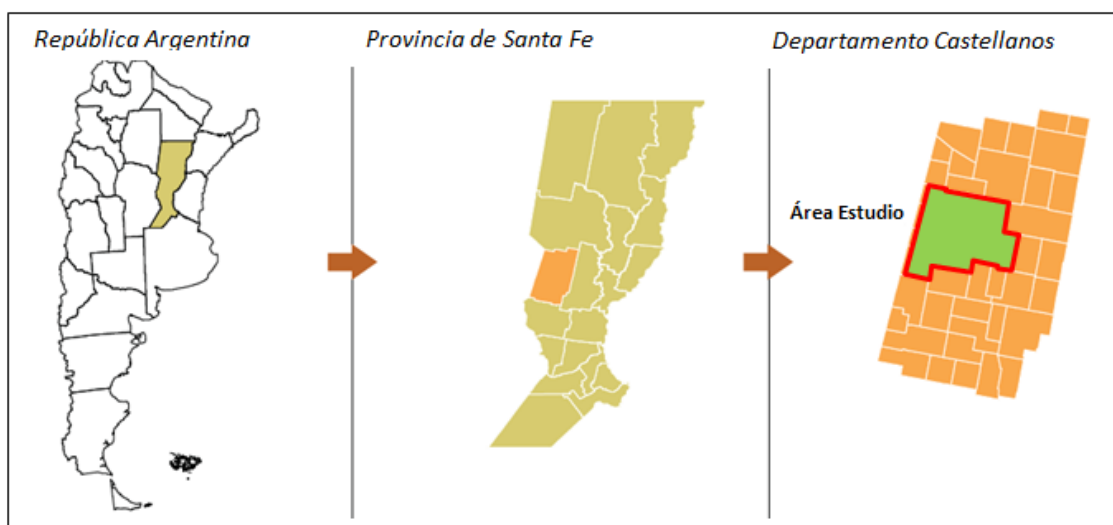



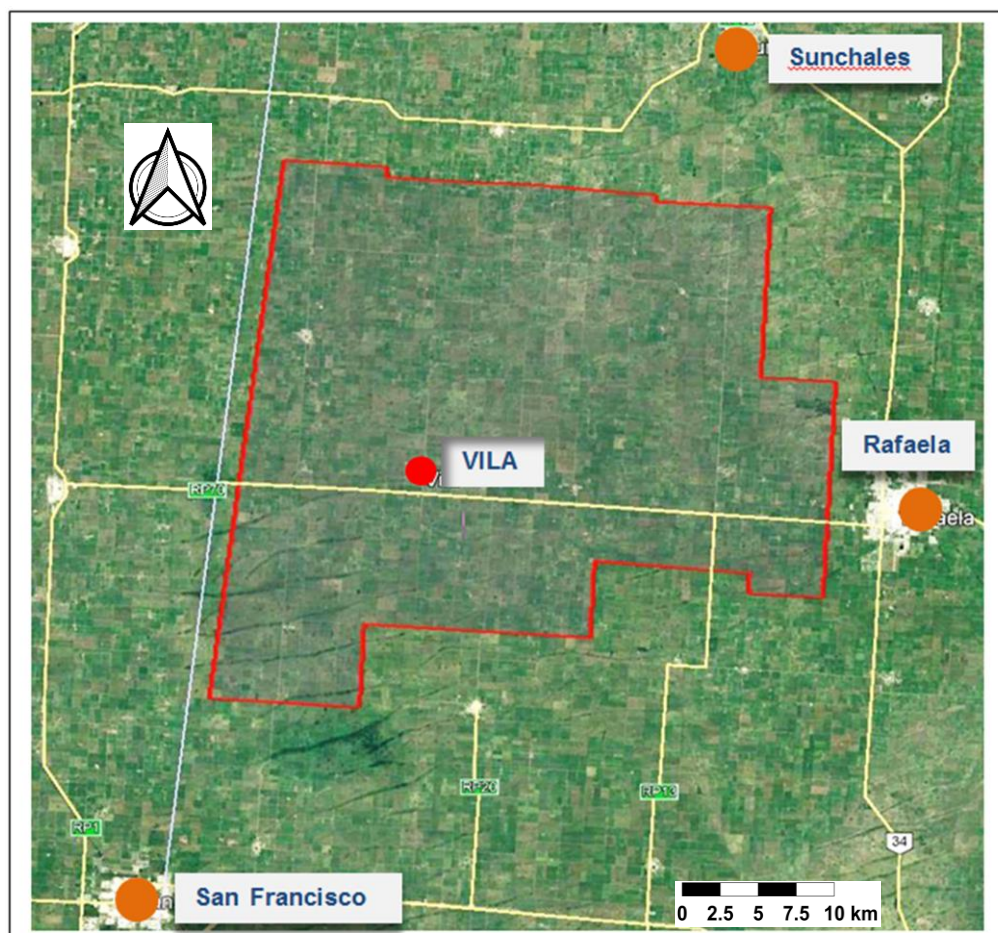
FIGURA 1: Localización del área de estudio en la República Argentina - Provincia de Santa Fe - Departamento Castellanos.

Considerando como centro del área de interés a la localidad de Vila, la misma se encuentra a 33 km al Oeste de la ciudad de Rafaela, a 36 km al Norte de la de San Francisco (Prov. de Córdoba) y a 38 km al Sur de la de Sunchales, siendo estas tres, las ciudades cercanas más importantes en cuanto a sus actividades: industrial, servicios, logística y comercial. En relación a la capital de la provincia, Vila se localiza a 120 km al Oeste de la ciudad de Santa Fe y a 225 km al Noroeste de la de Rosario (Figura 3).



FUENTE: SCIT (2020).

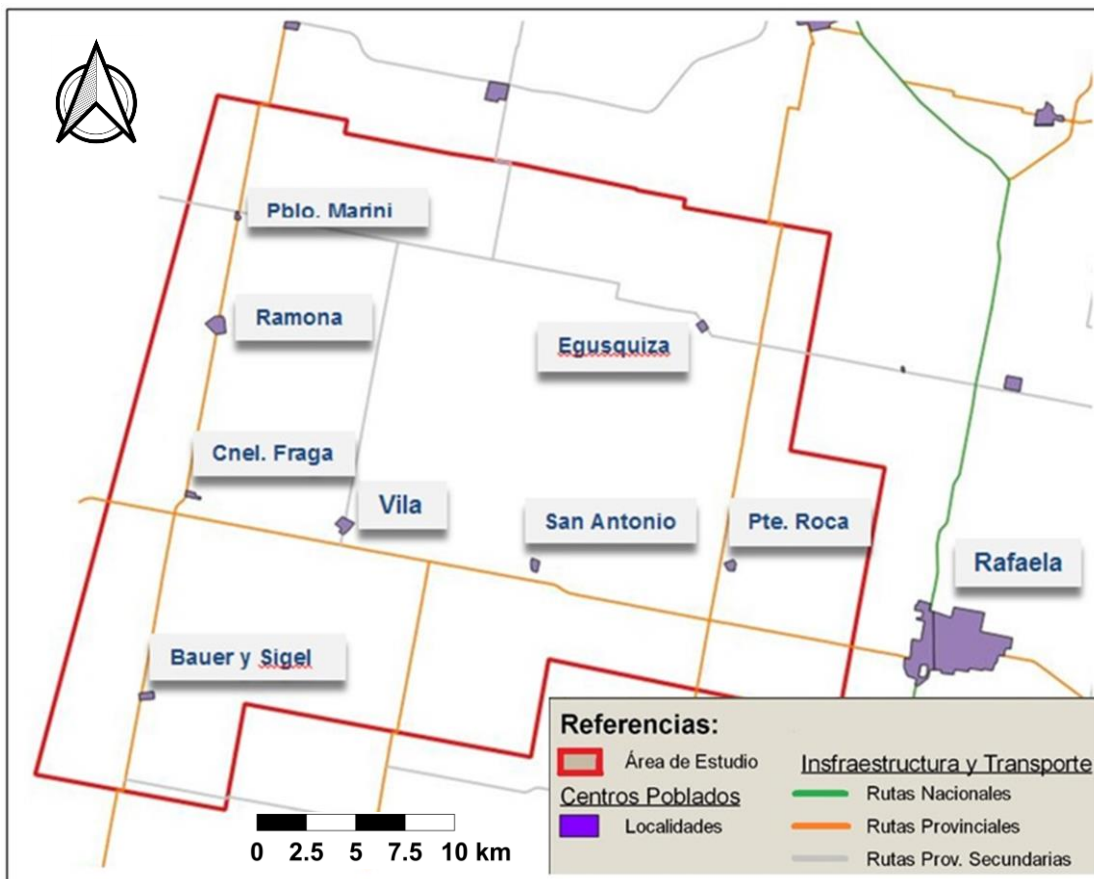
FIGURA 2: Área de estudio incluye once distritos del Dep. Castellanos - Prov. de Santa Fe.



FUENTE: Google Earth (2021), modificado por el autor.

FIGURA 3: Ubicación de la localidad de Vila en relación a las ciudades más importantes aledañas al área de interés.

A continuación, se puede apreciar en la Figura 4, las principales localidades y rutas provinciales localizadas en el área de estudio.



FUENTE: SCIT (2020).

FIGURA 4: Rutas nacionales, provinciales y localidades del área de estudio.

1.3.2 Características Climáticas

Clima

Considerando los regímenes térmico y pluviométrico, la cuenca presenta un clima Templado cálido sin estación seca.

Temperatura

En el área de estudio la media anual de temperatura varía entre 17,5 y 19,5 °C, siendo atravesada por la isoterma de 18 °C. La temperatura máxima media es de 32 °C y sucede en el mes de enero y la mínima media es de 6,6 °C y ocurre en julio.

Humedad

La humedad relativa media anual es de 76% y la misma expresa la presencia de vapor de agua en la atmósfera. En los meses de verano su valor medio varía entre 72 y 80% (P. Leva y M. García, 2013) [5].

Presión y Vientos

La presión media normal es de 1002,6 HPa, produciéndose la mínima en los tres meses de verano donde alcanza valores de 1000,0 HPa. En relación a los vientos, los dominantes son de los sectores: Norte, Este y Sur (pampero), y los meses de mayor frecuencia son los de agosto y septiembre (Leva y García, 2013) [5].

Evapotranspiración potencial

La evapotranspiración potencial (ETP) anual es de 900 mm, los déficit de agua se presentan durante el verano siendo enero el mes más seco con una ETP de solo 145 mm.

Precipitación

La misma se encuentra entre las isoyetas de 800 y 1200 mm, con una marcada variabilidad en el régimen pluvial anual que va desde los 500 mm, en los años secos, hasta superar los 2000 mm en los húmedos, con precipitaciones muy intensas. Además, la frecuencia de precipitaciones intensas se ha incrementado desde fines de 1970, pero esta tendencia ha sido más marcada a partir de 1990. Esto ha sido verificado en varios estudios (MAH, UNL, INA, INTA, 2007) [6].

Tales estudios han verificado que la media de las precipitaciones anuales en la estación meteorológica Rafaela, ha variado de 880 mm en el período 1930-1970 a 1044 mm en el lapso 1971-2007. Esto significa duplicar los excesos de agua de un período a otro, observándose un incremento importante en los caudales medios del río Salado, siendo de 70 m³/s en el primer período y de 176 m³/s en el segundo indicando un aumento de más del 100% en términos medios anuales.

El período normal de inundaciones ocurre a finales del verano en los meses de febrero o marzo, donde las precipitaciones suelen superar los 300 mm. Esto sucedió durante el anegamiento del año 2007 cuando se registró un fenómeno climático extremo, con excesos de lluvias, registrándose en la localidad de Rafaela una precipitación acumulada de 735 mm durante los meses de febrero y marzo (Servicio Meteorológico Nacional - SMN, 2008) [7].

También, se produjeron fenómenos climáticos similares durante los meses de enero y marzo del año 2014 con una precipitación acumulada de 550 mm, entre diciembre de 2015 y abril de 2016 con una precipitación acumulada de 814 mm y en diciembre de 2016 y enero 2017 donde la precipitación acumulada fue superior a los 500 mm. En cambio, en el período que abarca desde noviembre de 2017 a marzo de 2018 se produjo un fenómeno climático extremo, con déficit de lluvias, caracterizado por escasas precipitaciones, muy por debajo de lo normal, con una precipitación acumulada de sólo 131 mm.

1.3.3 Características Geomorfológicas

El área de estudio se encuentra localizada en el sector Suroeste de la Cuenca del Arroyo Cululú (Figura 5). La misma constituye la mayor sub-cuenca del río Salado ubicándose en su tramo inferior próxima a su desembocadura. La cuenca del Cululú presenta una longitud aproximada Oeste-Este de 120 km y una Norte-Sur promedio de 80 km con una superficie total de 9.636 km².

Su morfología está controlada por lineamientos tectónicos de orientación general N-S y NE-SW. Sus cabeceras se encuentran en el NE de la provincia de Córdoba y el NW de la de Santa Fe. Se trata de un área plana de pendiente muy suave hacia el Este. Es una sub-cuenca asimétrica con mayor desarrollo en la red de afluentes en el sector Oeste, se trata de cañadas subparalelas que se integran hacia el Este con la red fluvial.

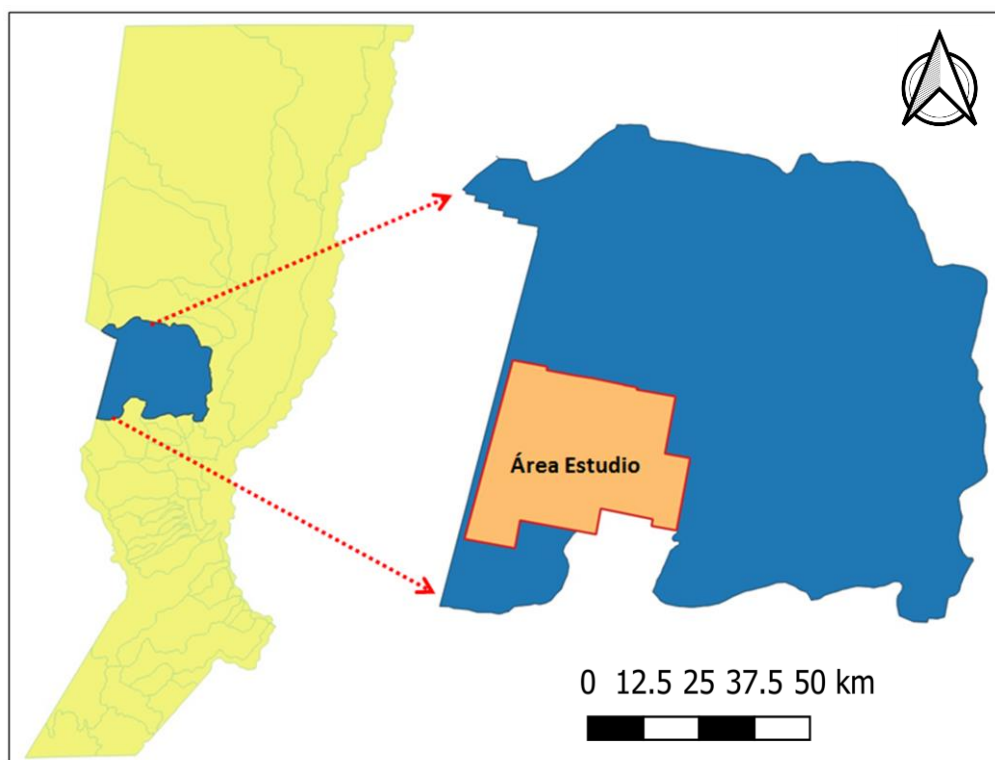


FIGURA 5: Ubicación de la Cuenca del arroyo Cululú en el centro-oeste de la Prov. de Santa Fe (izquierda) y localización del área de estudio en dicha cuenca (derecha).

La cuenca del Cululú representa un claro ejemplo donde se reconocen cambios climáticos, registrados hace miles de años en la gran llanura chaco-pampeana, a partir de un conjunto de sedimentos, suelos y de formas de modelado de los rasgos actuales del paisaje originadas en el período Cuaternario Superior (D. Krohling y E. Brunetto, 2013) [8].

La dinámica hídrica actual está definida por factores geológicos y climáticos. Entre los geológicos domina el estilo tectónico caracterizado por lineamientos de rumbo NE-SW y NW-SE, que delimitan bloques elevados, hundidos y basculados con elevaciones de pocos metros, pero que en llanura producen efectos morfológicos importantes. Los movimientos sucedidos pueden considerarse como acomodamientos modernos leves de estructuras antiguas. Dado que en esta región la cobertura de sedimentos no consolidados que cubre el basamento de rocas tiene centenares de metros, las deformaciones generadas por desplazamiento sobre fallas se distribuyen en las capas superficiales en forma de suaves pliegues. Estas fallas no generan rupturas en la superficie (D. Krohling y E. Brunetto, 2013) [8]. Entre los principales elementos geomorfológicos se debe destacar:

Cañadas: constituyen depresiones lineales rectas de llanura, poco profundas (1 m), relativamente anchas (200 a 400 m) y de mayor longitud (5 a 35 km), que colectan agua y sirven como vías de escurrimiento permanente o temporario. Generalmente están cubiertas por pajonal o vegetación palustre. Las cañadas de la cuenca del Culutú son en general lineamientos de origen tectónico que se suceden en forma paralela a intervalos irregulares. Muchas son asimétricas, esta característica puede ser observada, a pesar del escaso relieve, por las franjas de vegetación. En el centro de las cañadas, sector más profundo, puede encontrarse agua permanente con vegetación palustre y a ambos lados aparecen fajas de bañados con pajonales de diferentes anchos, demostrando la asimetría (M. Iriondo, 1983) [9].

Paleocañadas: se trata de depresiones que corresponden principalmente a cursos de agua actualmente desactivados que han funcionado en períodos del cuaternario y que presentan control estructural. Estas atraviesan perpendicularmente bloques sucesivos y se suceden en forma regular (P. Pasotti, 1969) [10].

Hoyas de deflación: son depresiones generalmente circulares, aunque a veces son elípticas, de escasa profundidad que fueron erosionadas por el viento durante un período de tiempo anterior de clima seco (árido o semi-árido). Estas depresiones forman pequeñas lagunas o lugares transitorios de acumulación de agua.

Cubetas o bañados de origen hídrico: son áreas deprimidas que ocupan grandes extensiones, hasta cientos de Km², en las cabeceras de las cuencas fluviales de llanura y se encuentran cubiertas de agua durante largos períodos (semanas o meses). Son alimentadas por el agua de lluvia la cual cubre la depresión con apenas algunos centímetros de profundidad y no presentan sedimentos palustres. La masa de agua se mueve muy lentamente sin transportar sedimentos a favor de las suaves pendientes hacia áreas de cotas más bajas. El agua residual de estos bañados termina escurriendo a través de las cañadas o cauce fluvial (M. Iriondo y E. Drago, 2004) [11].

1.3.4 Características de los Suelos

Los suelos “zonales” más difundidos son los Argiudoles (típicos y ácuicos, familia arcillosa fina), los mismos están bien y moderadamente bien drenados, con horizontes superficiales de textura franco limosa con muy bajo contenido de arena.

En las cañadas predominan los suelos pobremente drenados, sódicos y salino-sódicos (Natracuálfes típicos).

En relación a la Capacidad y Aptitud de Uso de los suelos del área de estudio, los mismos corresponden a las clases 1, 2, 3, 4 y 5 de las ocho posibles. A continuación se las describe según M. Pilatti *et al.* (2013) [12]:

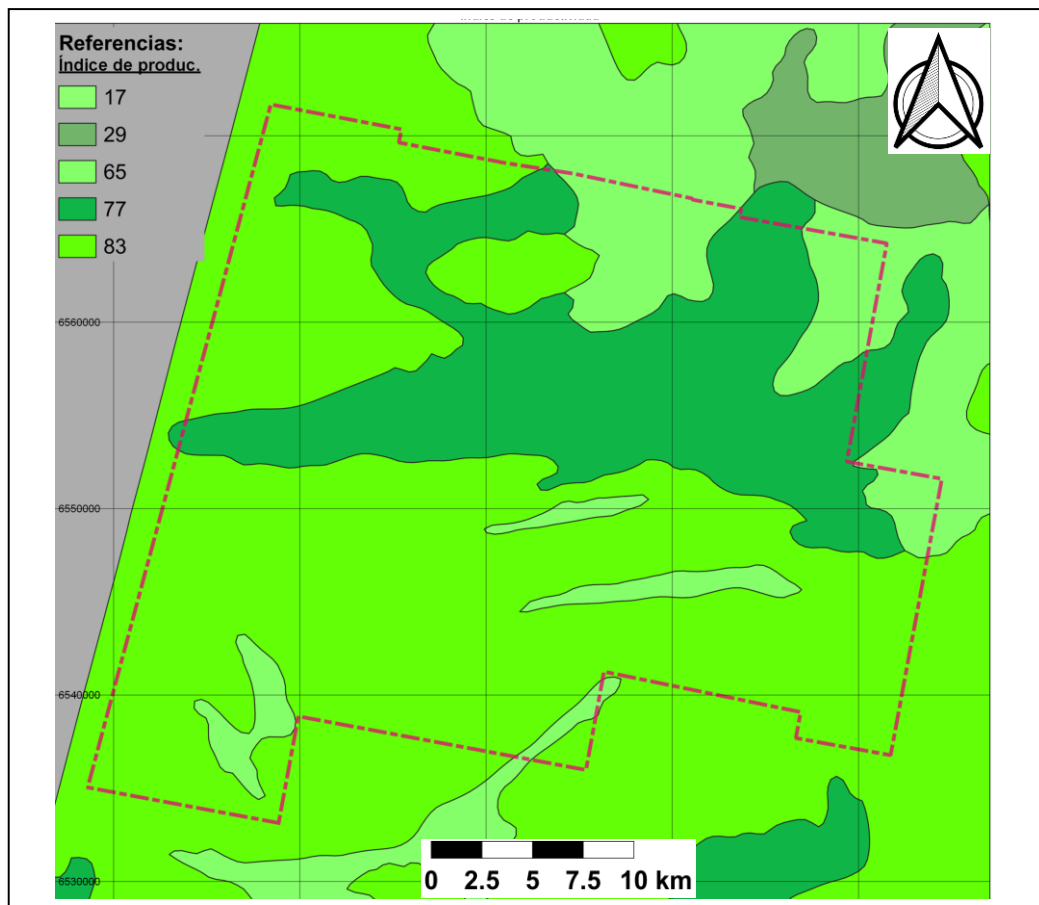
_La clase 1 indica una capacidad y aptitud de uso del suelo netamente agrícola sin limitaciones para un amplio número de cultivos. Corresponden a suelos con relieve plano, profundos, sin problemas de erosión, bien drenados, no sujetos a inundación y con un índice de productividad (IP) muy alto entre 70 y 85 ocupando el 11% de la cuenca.

_La clase 2 indica una capacidad y aptitud de uso del suelo agrícola-ganadera con algunas limitaciones que reducen el tipo de cultivos y/o requieren practicas moderadas de manejo y conservación del suelo. Corresponden a suelos con pendientes suaves, profundidad inferior a la ideal, moderada susceptibilidad a la erosión, daños ocasionados por inundaciones y con un IP alto entre 55 y 69 encontrándose en el 19% de la cuenca.

_La clase 3 indica una capacidad y aptitud de uso del suelo ganadera-agrícola con limitaciones más severas que reducen la elección del cultivo y/o exigen prácticas intensas de manejo y conservación del suelo. Corresponden a suelos con pendientes moderadas o medias, poca profundidad efectiva, alta susceptibilidad a la erosión, frecuentes inundaciones y con un IP medio a alto entre 40 y 54 hallándose en el 18% de la cuenca.

_Las clases 4 y 5 indican una capacidad y aptitud de uso del suelo ganadera intensiva con limitaciones muy severas que restringen la elección del cultivo y/o exigen prácticas de manejo muy difíciles de aplicar. Corresponden a suelos con pendientes fuertes, suelos superficiales, severa susceptibilidad a la erosión, frecuentes inundaciones o excesiva humedad y con un IP medio a bajo entre 20 y 39 ocupando el 14% de la cuenca.

A continuación, la Figura 6 muestra el índice de productividad para las clases de suelo presentes en el área de estudio.



FUENTE: SCIT, (2019).

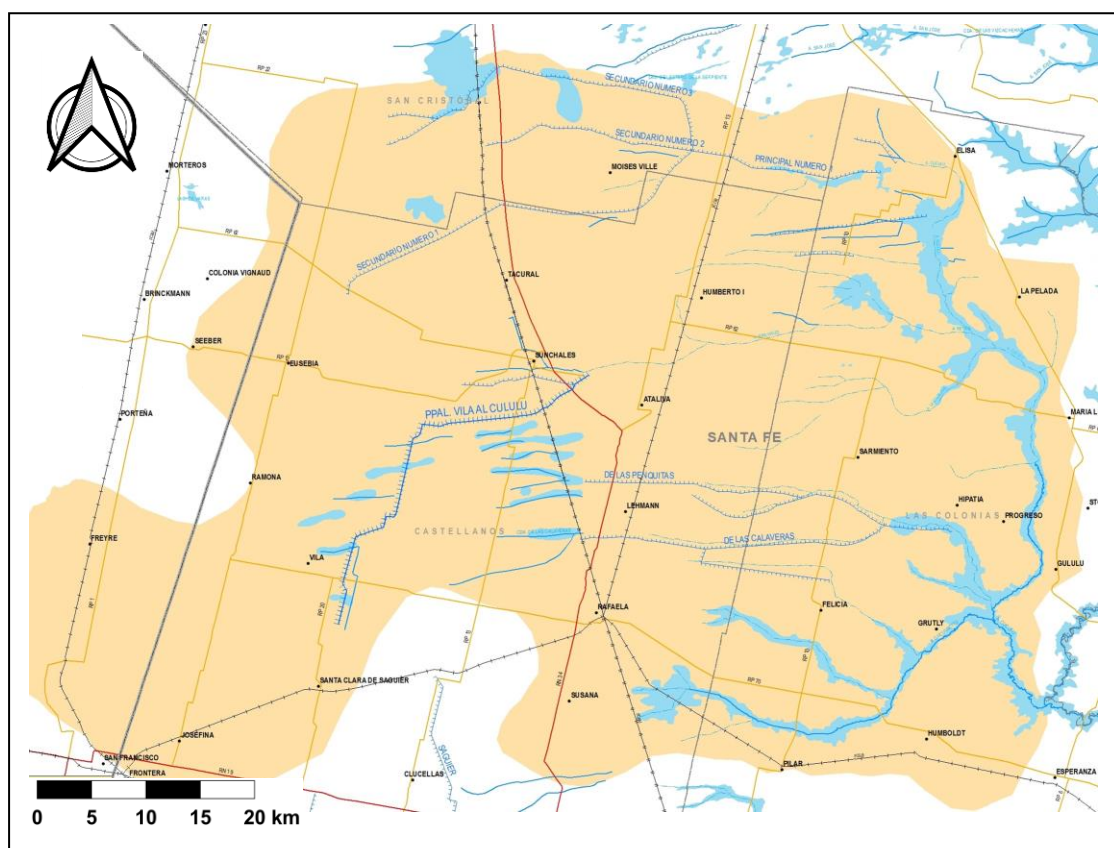
FIGURA 6: Distribución del Índice de productividad en función de las clases de suelo.

1.3.5 Características Hidrológicas

La cuenca del Cululú es una cuenca de llanura, caracterizada por divisorias amplias y una red de drenaje formada por cañadas interconectadas que hacia el Este se integran en valles fluviales hasta alcanzar el colector principal correspondiente al arroyo Cululú. Desde el punto de vista hidrológico, la cuenca del arroyo Cululú es muy importante dado que es el afluente del río Salado más próximo a su desembocadura y quien aporta los mayores caudales.

Los cauces y lagunas o bajos con agua permanente ocupan 710 km² en toda la cuenca del Cululú. Los suelos de muy baja aptitud productiva que tienen agua en superficie periódicamente cubren 1.600 km². Además, existen unos 600 km² de tierras de mejor aptitud productiva que luego de intensas precipitaciones presentan agua en superficie durante varios días hasta unas pocas semanas (C. Paoli *et al.*, 2013) [13].

Durante el siglo pasado se construyeron en la cuenca numerosos canales de drenaje principales, secundarios y terciarios, que fueron diseñados y construidos por diferentes comités de cuenca. La cuenca tiene 180 km de red natural de drenaje y más de 1.000 km de canales (Figura 7). Las escasas pendientes al Oeste de la cuenca producen que durante las lluvias intensas o períodos de exceso hídrico se produzca el anegamiento de extensas áreas lo cual ha llevado a la construcción de canales principales destacándose el denominado Canal Vila-Cululú y Canal N° 1, construidos ambos en la década de 1940. A partir de 1970, la sucesión de períodos de excesos hídricos generó un aumento de las áreas anegadas con lo cual se incrementó el número de canales secundarios y terciarios.



FUENTE: FICH (2019).

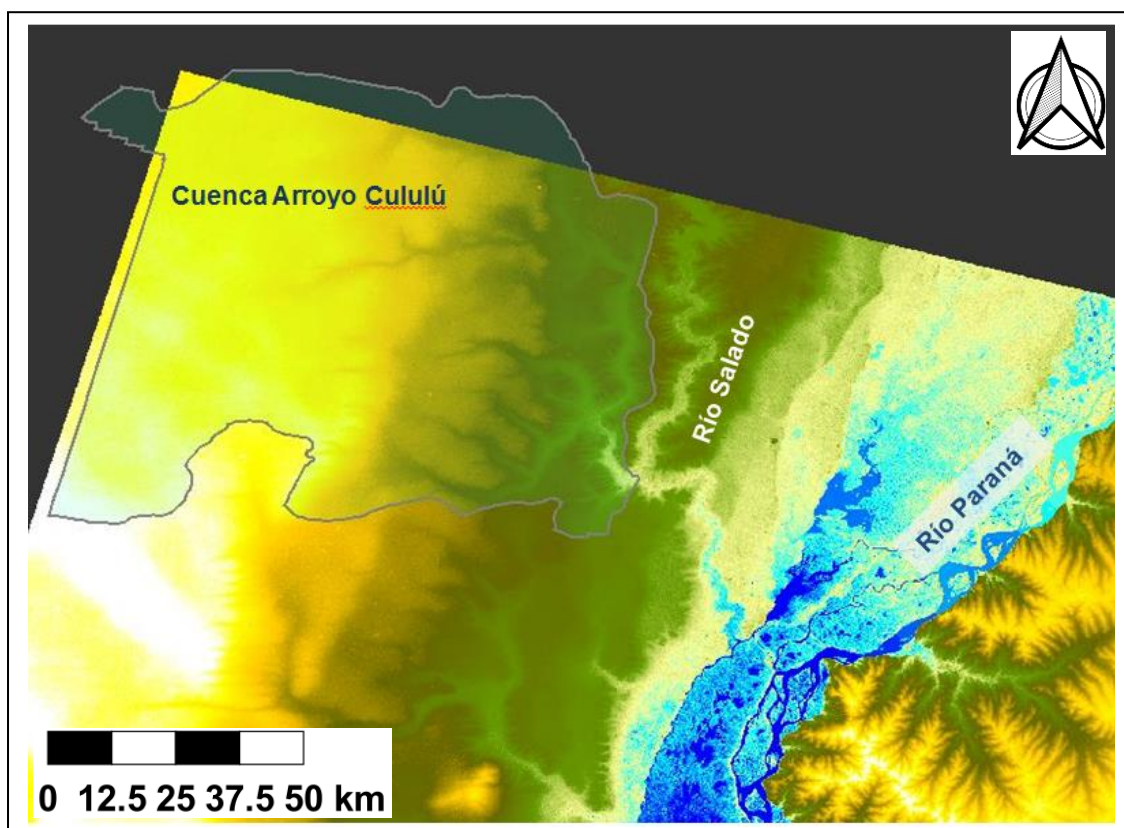
FIGURA 7: Red de drenaje natural y artificial de la cuenca del Arroyo Cululú.

El canal principal Vila - Cululú discurre en el sector Oeste de la cuenca, en las nacientes, con dirección Sur-Norte recibiendo aportes de canales secundarios y terciarios totalizando 218 km. Este sector Oeste tiene forma de cubeta con una muy limitada capacidad de drenaje, con lo cual los canales ayudan a disminuir el tiempo de permanencia de los excedentes hídricos, sin embargo, la evacuación de los mismos está limitada a la capacidad de desagüe del canal principal (12-15 m³/s).

Además de las mencionadas condiciones del relieve, se debe indicar que la problemática hídrica de la cuenca se produce por: 1. Sucesión de épocas de excesos y déficit hídricos, 2. Canalizaciones individuales aguas arriba y debajo de la cuenca, 3. Presencia de obras de infraestructuras puntuales y 4. Falta de diferenciación de zonas con mayor productividad de otras con mayor capacidad de almacenamiento de excedentes hídricos superficiales (C. Paoli *et al.*, 2013) [13].

1.3.6 Características Topográficas

La cuenca del Cululú pertenece a la ecorregión del Espinal. Su relieve en el sector Oeste, correspondiente a sus nacientes, es homogéneo y se desarrolla sobre un plano alto, denominado Domo Occidental, con una altura promedio entre los 100 y 114 msnm (Figuras 8). En dicho sector, la pendiente topográfica promedio es del 0,1%, por lo tanto, no existe un escurrimiento jerarquizado predominante y, en épocas normales, los flujos verticales de agua predominan sobre los horizontales. En este tramo superior de la cuenca se encuentra su punto más alto localizado cerca de la ciudad de San Francisco con 114 msnm.



FUENTE: USGS (2020).

FIGURA 8: MDT con la cuenca del Arroyo Cululú superpuesta.

Con motivo de conocer el sentido de la pendiente en el área de estudio, se efectuaron dos perfiles topográficos que la atraviesan por su centro, uno con dirección Oeste-Este de 40,6 km de longitud y el otro con Sur-Norte de 31,3 km de largo, ver Figura 9. Luego, se puede apreciar en la parte de arriba de la Figura 10, el perfil con sentido Oeste - Este que comienza con una altura promedio de 105 msnm para luego descender formando una cubeta u hoya con una altura mínima de 100 msnm y luego vuelve a subir a 105 msnm para finalmente descender a 99 msnm. En la parte de abajo de la misma figura se observa el perfil interpolado el cual muestra que en 40,6 km de longitud, el terreno descende solo 6 m en altura dando entonces una pendiente de tan solo 0,015%.

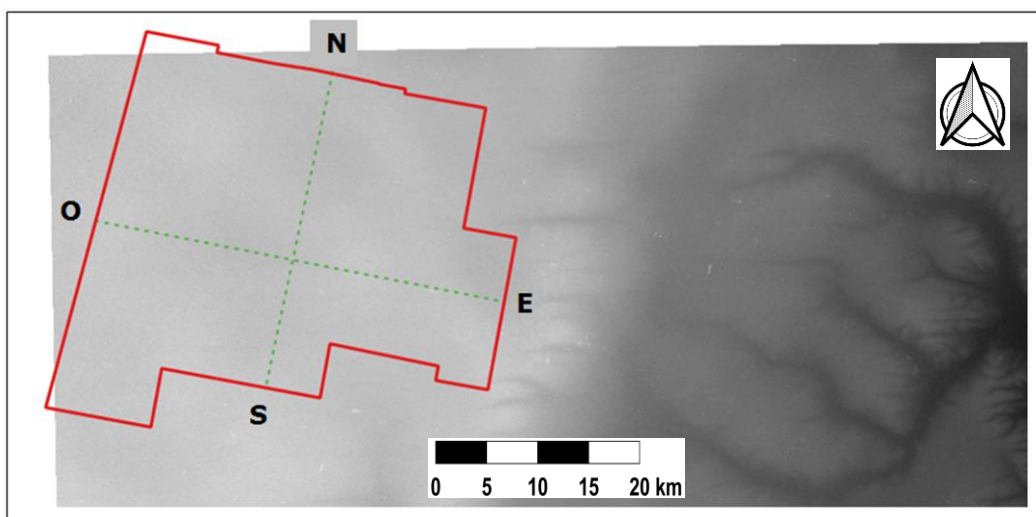


FIGURA 9: Perfiles topográficos sobre el área de estudio.

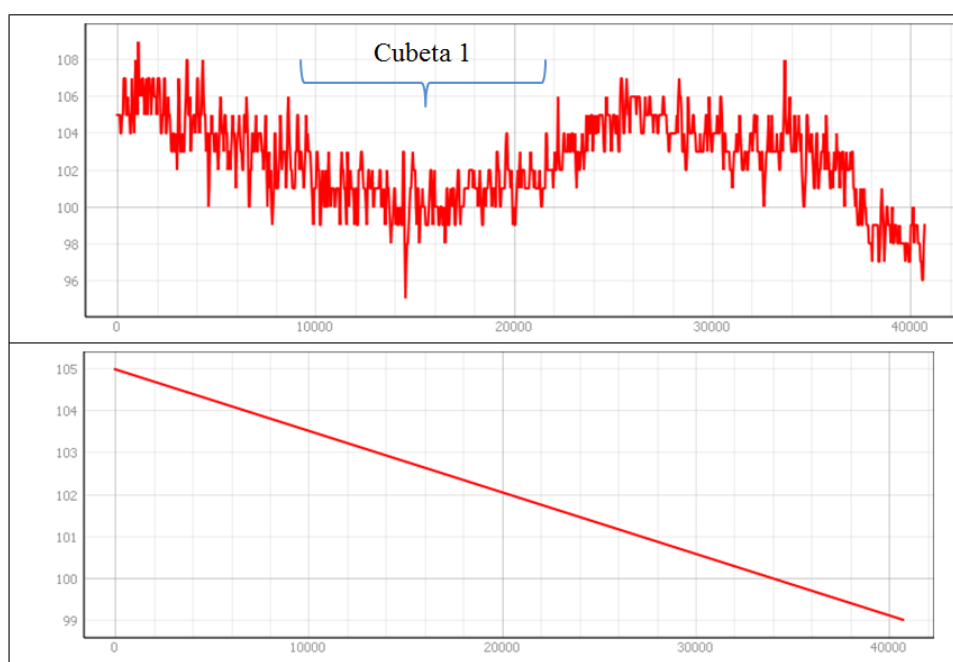



FIGURA 10: Perfil topográfico con sentido Oeste-Este (arriba) y el mismo interpolado (abajo)

La depresión observada en el perfil mencionado se corresponde con una de las cubetas o bañados analizados en este informe con objeto de detectar las áreas anegadas, específicamente la denominada cubeta 1, mostrada en la Figura 11.



FUENTE: USGS (2020).

FIGURA 11: Perfiles topográficos atravesando las cubetas 1 y 2 del área de estudio.

Con respecto al segundo perfil (Figura 12), el mismo tiene sentido Sur - Norte, iniciando con una altura promedio de 107 msnm para luego descender formando la cubeta 2, a continuación sube levemente y luego vuelve a bajar constituyendo la cubeta 1, finalmente sube ligeramente para terminar a una altura de 101 msnm. En la parte de abajo de la Figura 12 es posible apreciar el perfil interpolado el cual indica que en 31,3 km de longitud, el terreno desciende también 6 m en altura dando entonces una pendiente de apenas 0,019%.

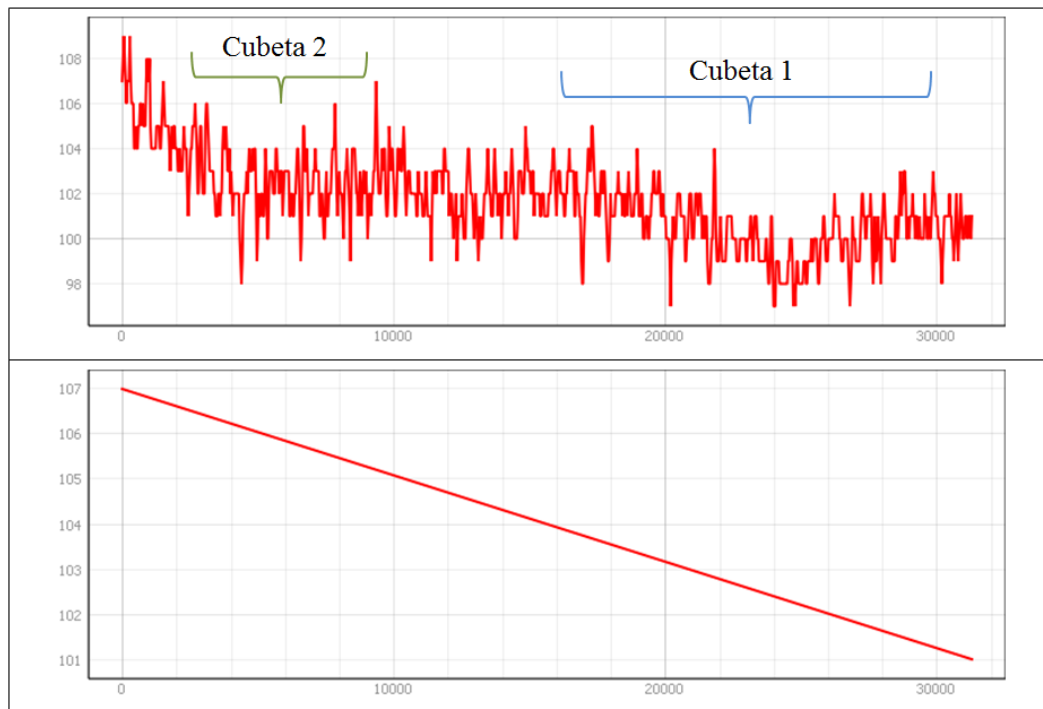


FIGURA 12: Perfil topográfico con sentido Sur-Norte (arriba) y el mismo interpolado (abajo).

1.3.7 Características Productivas

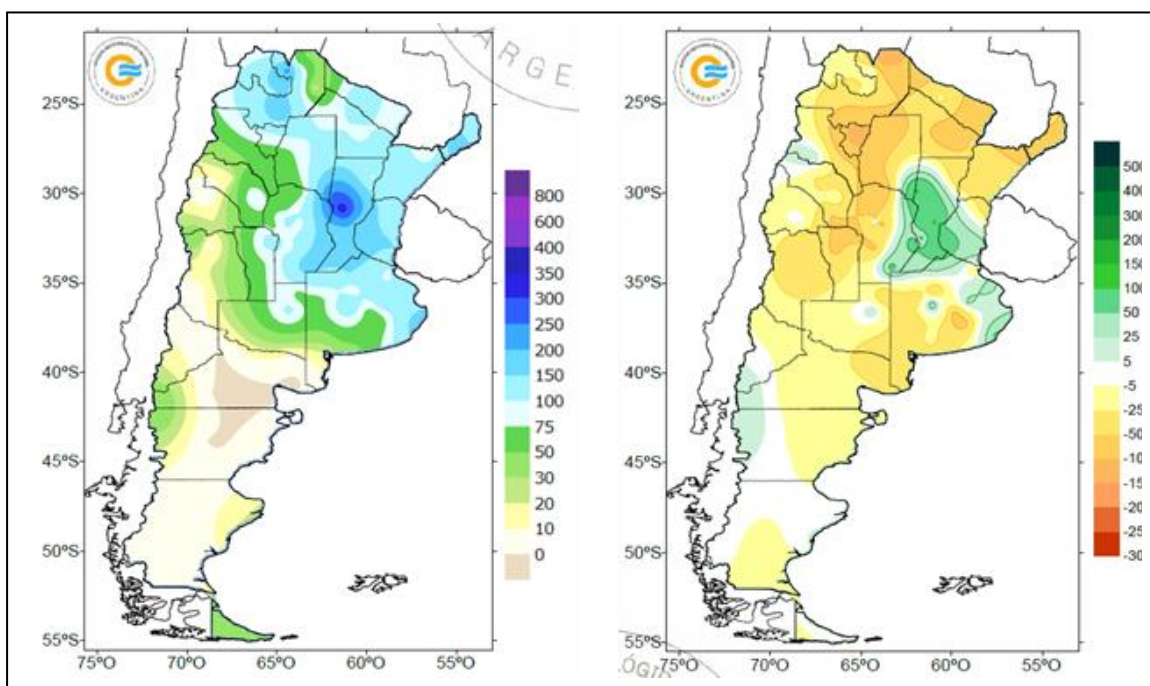
Actualmente en el área de estudio conviven distintas actividades agropecuarias, tales como: las agrícolas y las ganaderas de carne (cría e invernada) y lechera, ambas con ganado bovino. En el caso de agricultura, prevalece la siembra directa o labranza cero, que implica la no remoción del suelo y la generación de cobertura a través de restos vegetales muertos (rastros). La densidad, altura y consistencia de estos es variada en función del cultivo a utilizar en la rotación, siendo los principales los más comunes en la provincia: soja, trigo y maíz, sin embargo, se presentan diferencias locales con mayor proporción de soja de 2da. y aumento de los cultivos de sorgo, maíz y girasol.

En el caso de la lechera predomina la intensiva (tambo), en la cual los cultivos incluidos en la rotación son la alfalfa (tres años), que constituye la pastura base, y luego dos años con cultivos anuales (gramínea de invierno y de verano). En la primera década de este siglo los bovinos de tambo disminuyeron un 17%. En relación a la ganadería de carne se observa una disminución en la superficie utilizada mayor al 5% en el período 2000 - 2010, lo cual fue acompañado por un descenso del 20% de las existencias de ganado bovino.

En la opinión de M. Pilatti (2013) [12], el área de estudio está asentada en suelos fértiles con alta capacidad productiva. La actividad primaria ha mutado en los últimos años desde una actividad típicamente ganadera-agrícola (década de 1960 a 1980) hacia una agrícola-ganadera con predominio del doble cultivo anual trigo - soja, con lo cual se han reducido notablemente los costos de producción y manejo.

1.3.8 Evento Climático Extremo

Extensas zonas de la Pampa Húmeda vienen experimentando una alternancia de períodos de sequía y episodios lluviosos muy concentrados en el tiempo y en el espacio. En particular, durante el período del 22/12/2016 al 13/01/2017 el área de estudio recibió un fenómeno climático extremo constituido por precipitaciones que superaron los 500 mm, es decir, en 22 días llovió el 50% de lo que lo hace en un año. En la Figura 13 se pueden apreciar los valores acumulados de precipitación (mm) durante enero de 2017 en todo el país. Se observa claramente como los mayores valores de lluvias (entre 350 y 400 mm) tienen como epicentro el centro-oeste de la provincia de Santa Fe donde se localiza el área de interés. También, esta figura muestra las anomalías positivas de precipitación en el mes de enero de 2017 (Servicio Meteorológico Nacional, 2017), es decir, cuanto más de lo normal llovió, mostrando valores superiores a las 100 mm.



FUENTE: Servicio Meteorológico Nacional (2017).

FIGURA 13: Precipitación acumulada en mm (izq.) y anomalía de precipitación en mm (der.) en enero de 2017.

A continuación, la Tabla 1 muestra que los excesos de precipitación fueron de tal magnitud que se produjeron nuevos records de precipitación acumulada en 24 horas en dos estaciones del Servicio Meteorológico Nacional localizadas muy próximas al área de estudio, se trata de las ubicadas en las ciudades de Rafaela y Sunchales. También, la Tabla 2 muestra los datos de lluvia de referencia registrados por informantes locales (integrantes o presidentes comunales, profesionales, etc.) del INTA - Estación Rafaela en distintas localidades del área de estudio y otras cercanas a la misma.

TABLA 1: Estaciones meteorológicas con récord diario de precipitación el 03/01/2017.

Estación	Precipitación acumulada en 24hs (mm)/día de ocurrencia	Valor récord anterior (mm)/año de ocurrencia	Período de referencia
SUNCHALES	157.0 / 3	120.0 / 2011	2010 - 2017
RAFAELA	99.0 / 3	70.0 / 2015	2013 - 2017

FUENTE: Servicio Meteorológico Nacional (2017).

TABLA 2: Precipitaciones de referencia durante el período 22/12/2016 al 13/01/2017.

Distrito	mm de lluvia (*)
Bauer y Sigel	320 a 450 al Norte
Eusebia	270
Ramona	+ de 450
Eustolia	+ de 450
Josefina	320
Fidela	+ de 500
Sunchales	+ de 500
San Antonio	+ de 480
Vila	+ de 400
Santa Clara de Saguier	+ de 400
Rafaela	400

FUENTE: Informantes locales del INTA - Estación Rafaela (2017).

Este evento meteorológico extremo, produjo una situación muy complicada en el área de interés, además se debe considerar que la napa freática se encontraba muy cerca de la superficie e incluso en los lugares más bajos se hallaba al ras o sobre el nivel del suelo. Por lo tanto, se anegó un porcentaje muy alto de los campos (Figuras 14 y 15), produciendo mortandad de plantas, tanto en pasturas de alfalfa como en cultivos de soja, maíz y sorgo, ocasionando un impacto muy negativo en la

producción de los cultivos agrícolas para cosecha o reservas de sistemas ganaderos y de las pasturas, con porcentajes de pérdidas superiores al 70% y en algunos sectores hasta del 100% (INTA, 2017) [14].



FUENTE: María Noel Herszkowicz (2016).

FIGURA 14: Lotes agrícolas del área de estudio completamente inundados.



FUENTE: Carlos Caracci y D.Faure (2017).

FIGURA 15: Lotes de maíz inundados en el área de interés que se perdieron.

En cuanto a la producción lechera, el porcentaje de la merma fue en el orden del 20% y 50%. Además, se vio muy comprometida la recepción de la leche por parte de las empresas lácteas dado que muchos caminos rurales quedaron cortados o con dificultades para el transporte de la misma. Varios productores tamberos del área de estudio tuvieron que cerrar sus tambos, dado que no habían terminado de recuperarse de una situación similar padecida en abril de 2016, cuando les ocurrió está a fines de diciembre principio de enero de 2017, encontrándose prácticamente sin reservas de fuerza de trabajo, financieras e incluso el alimento para el ganado (C. Caracci y D. Faure, 2017) [15], ver Figuras 16 y 17.



FUENTE: Fabian Amarante (2016).

FIGURA 16: Tambo inundado localizado en el área de interés.



FUENTE: Carlos Caracci y D.Faure (2017).

FIGURA 17: Otro tambo inundado en el área de estudio.

En cuanto a las áreas urbanas de las pequeñas localidades (Ramona, Vila, Pueblo Marini, etc.) la mayoría sufrió el anegamiento de sus calles y casas, con grandes dificultades para el traslado de personas, servicios, e incluso problemas de contaminación (Figura 18).



FUENTE: Carlos Caracci y D.Faure (2017).

FIGURA 18: Calles y plaza de la localidad de Vila inundados.

2. ESTADO DEL ARTE

2.1 MAPAS DE INUNDACIÓN DESDE IMÁGENES SAR

La producción de mapas de inundación a partir de imágenes radar es un tema que se empezó a investigar en la década de los años 1980 (F. Ulaby *et al.*, 1981) [16] y continúa hoy en día debido a que los sensores mejoraron y lo mismo sucedió con la capacidad de procesamiento de las computadoras (PC). Debido a esto, temas que antes parecían imposibles como mapear la inundación en áreas cubiertas por vegetación, hoy dejaron de serlo. A continuación, se efectúa una síntesis de la investigación realizada por la comunidad científica en los últimos 20 años.

S. Solbø e I. Solheim (2005) [17], señalan a la definición de umbrales como método tradicional para realizar el mapeo operativo de inundaciones empleando imágenes SAR en áreas no forestada. Los mismos son relativos a la escena considerada y se los emplea para generar áreas de entrenamiento que luego se clasifican de manera supervisada con un algoritmo de máxima probabilidad para obtener el mapa de inundación.

Para I. Belmonte y S. Caamaño (2009) [18], la teledetección a través de sensores remotos activos SAR, constituye una herramienta de gran utilidad para el desarrollo de sistemas de prevención, seguimiento y evaluación de inundaciones. Las autoras implementaron un algoritmo de clasificación no supervisado basado en segmentación para la determinación de superficies abiertas inundadas.

L. Pulvirenti *et al.* (2014) [19], discriminaron superficies de agua y lluvias fuertes utilizando imágenes COSMO-SkyMed durante eventos climáticos severos. Para esto emplearon un método no supervisado que permite distinguir las superficies de agua (cuerpos permanentes o áreas inundadas) de las sombras causadas por las fuertes precipitaciones en las imágenes SAR de banda X. El algoritmo está basado principalmente en técnicas de segmentación de imágenes y en lógica difusa, consta de dos pasos principales: 1) detección de regiones de retrodispersión especular que aparecen oscuras en una imagen SAR, la cual representa el mecanismo de dispersión propio de la interacción de la señal con el agua; y 2) clasificación de cada región detectada a través de la lógica difusa, el algoritmo integra diferentes reglas para la detección de áreas oscuras, así como para su clasificación basada en

características radiométricas y de formas extraídas de la imagen SAR segmentada y de los datos auxiliares (mapa de cobertura del suelo e imagen óptica).

L. Pulvirenti *et al.* (2014) [20], realizaron una evaluación de daños causados por una inundación empleando datos multitemporales COSMO-SkyMed y modelos hidrodinámicos. Sin embargo, una fuerte limitación de estos modelos numéricos es la falta de información sobre la extensión real de la inundación y la dinámica de las fases de inundación y retroceso. La extensión de la inundación puede estimarse a través de datos SAR y aprovechando el corto tiempo de revisita de las imágenes proporcionadas por la constelación COSMO-SkyMed (CSK) de cuatro satélites, es posible también monitorear su dinámica temporal.

E. Pottier y L. Ferro-Famil (2018) [21], sostienen en relación al uso de imágenes SAR para mapear inundaciones que:

- Los datos de EO pueden ayudar a comprender, describir, monitorear y modelar estos eventos;
- Son pertinentes tanto los sensores pasivos (ópticos) como los activos (SAR / InSAR);
- Es muy importante aprovechar el sinergismo entre ambos sensores (revisión, resolución espacial, información espectral, etc.);
- La tarea no es tan "simple" dado que dichos sensores poseen diferentes: parámetros de adquisición, características de la escena, longitud de onda y además se aplican a distintos regiones geográficas con diferentes huellas;
- Finalmente, concluyen indicando que el recurso, es decir, las imágenes ópticas y SAR de los satélites Sentinel 1/2/3 de la ESA, está garantizado durante los próximos 15 a 20 años.

L. Giustarini *et al.* (2015) [22], sostienen que los mapas de inundación derivados de las imágenes SAR son el resultado de diversos métodos aplicados en el procesamiento de las imágenes. Dado que no existe un procedimiento perfecto ni una mejor práctica para seleccionar uno sobre otro, el procedimiento de mapeo elegido puede introducir errores o incertidumbres en el mapa de inundación obtenido. Además, las observaciones SAR son susceptibles a fuentes de incertidumbre debido a las características de la imagen (p. ej., modo de la imagen, speckle, resolución) y perturbaciones del suelo (p. ej., viento, árboles que enmascaran el agua, geometría

del terreno). Aplicaron un método mixto que combina el umbral de retrodispersión especular de las superficies abiertas inundadas, la segmentación de las imágenes (crecimiento por regiones) y la detección de cambios

G. Boni *et al.* (2016) [23], indican que actualmente el uso de imágenes SAR está bien aceptado en los servicios operativos para la gestión de inundaciones. Sin embargo, advierten que en algunos casos las inundaciones pueden no ser registradas por los sistemas satelitales operativos, dado su baja resolución temporal, o por la necesidad de programar anticipadamente las adquisiciones de las imágenes SAR. En ese sentido, los autores concluyen que para proporcionar a los administradores de emergencias un mapeo rápido y completo de los eventos de inundaciones, es necesario: 1) lograr una programación de las adquisiciones de las imágenes SAR basada en las predicciones de los modelos de inundación y 2) hacer un uso conjunto de los diferentes datos de satélites SAR con el fin de aprovechar las adquisiciones pre-programadas en grandes áreas (Sentinel 1), como, las que se obtienen bajo demanda específica en áreas de interés particular (COSMO-SkyMed).

U. Donezar-Hoyos *et al.* (2017) [24], analizaron la aplicabilidad de las imágenes Sentinel-1 en la detección y delineación de información de desastres naturales en el marco de los servicios Copernicus EMS. Emplearon imágenes SAR del Sentinel 1 en polarización VH para la detección de zonas inundadas y utilizaron un algoritmo de clasificación supervisada de distancia.

M. Clement *et al.* (2017) [25], adaptaron una metodología de detección de cambios y determinación de umbrales para mapear inundaciones empleando una serie multitemporal imágenes del satélite SAR Sentinel 1. Utilizaron las dos polarizaciones disponibles, VH y VV y compararon su precisión respectiva para delimitar el agua superficial, determinaron que la VV produce mejores resultados en la clasificación de áreas abiertas inundadas.

E. Cooper *et al.* (2018) [26], indican que las imágenes de los instrumentos SAR satelitales contienen gran cantidad de datos sobre la posición del agua durante un evento de inundación. La información generada desde las imágenes generalmente cubre un área extensa, sin embargo, solo es relevante por un corto período de tiempo si los niveles de agua están cambiando rápidamente. Los autores combinaron los datos de las imágenes SAR con las predicciones continuas de un modelo

hidrodinámico y así consiguieron producir un mejor pronóstico y en un menor tiempo que si hubiesen empleado solo el modelo.

A. Benoudjit y R. Guida (2019) [27], propusieron una forma rápida para mapear la inundación a partir de imágenes SAR utilizando un clasificador supervisado. La metodología está automatizada ya que el entrenamiento del clasificador se hace a partir de máscaras de agua y de suelo derivadas del Índice de Agua de Diferencia Normalizado (NDWI) extraído de las imágenes ópticas Sentinel 2. Ambas, una imagen SAR Sentinel 1 y una imagen óptica previas al evento se necesitan para entrenar al clasificador supervisado para identificar luego la inundación en la imagen SAR del evento. Concluyeron que este algoritmo de Detección de Cambios ofrece en general un buen compromiso entre el tiempo de cálculo y precisión de la clasificación.

S. R. S. Aldhshan *et al.* (2019) [28], efectuaron cartografías de áreas sometidas a inundaciones utilizando datos SAR del satélite Sentinel 1. Indicaron que tales imágenes permiten monitorear las crecidas repentinas y adicionalmente se pueden utilizar para evaluar los daños. Sostienen que la etapa fundamental en el procesamiento de la imagen SAR inundada es la estimación del valor umbral de retrodispersión que selecciona el algoritmo de cálculo binario para decidir si un pixel específico está inundado o no. También, resaltan que de las dos polarizaciones disponibles (VV y VH), optaron por utilizar la VV.

J. H. Reksten *et al.* (2019) [29], desarrollaron un sistema para detectar y delinear inundaciones con el uso de imágenes del satélite Sentinel 1. Sostienen que en las imágenes SAR las áreas inundadas muestran una retrodispersión más baja que las áreas circundantes no anegadas. Por lo tanto, para la detección de inundaciones, el sistema se basa en realizar una clasificación supervisada basada en la detección de cambios comparando una imagen de referencia adquirida antes de la inundación con la imagen propia del evento de inundación. Luego el algoritmo se aplica en dos pasos: 1) La Detección de cambios, se crea una imagen de Diferencia = Evento - Referencia y 2) Procesamiento de la imagen de Diferencia obtenida aplicando un clasificador supervisado de aprendizaje automático (Bosque Aleatorio).

Según B. Debusscher *et al.* (2019) [30], la cantidad de datos satelitales disponibles gratuitamente está creciendo rápidamente como resultado de los

programas de observación de la tierra, tal como Copernicus de la ESA. El análisis de estas enormes cantidades de datos geoespaciales y la extracción de información útil es una búsqueda constante. Indicaron que los SAR constituyen la herramienta preferida para el mapeo de inundaciones desde el espacio. Los autores presentaron un método alternativo para la detección de inundaciones basado en la descripción de la dinámica espacio-temporal en series de tiempo de imágenes de satélite a partir de gráficos que permiten una fácil interpretación de los cambios en la superficie.

Según H. Cao *et al.* (2019) [31], la detección de inundaciones en grandes extensiones empleando el método de clasificación no supervisado a partir de datos SAR, siempre se enfrenta al desafío del umbral automático dado que los histogramas de las imágenes de grandes superficies son unimodales, lo que dificulta la determinación del mismo. Los autores proponen un procedimiento de búsqueda para imágenes (Sentinel 1) que obedecen a la distribución gaussiana bimodal y un algoritmo de umbral no paramétrico, basado en histogramas, para identificar áreas de agua. Luego, los umbrales se integran en el algoritmo de segmentación por crecimiento de región para obtener el mapa de la inundación.

K. Ji y Y. Wu (2015) [32], sostienen que la polarización dual es un modo operativo típico de los satélites SAR. Proponen una descomposición de Cloude-Pottier modificada para investigar el rendimiento de las imágenes SAR de polarización dual en la extracción de los mecanismos de dispersión. Indican que la polarización dual HH-VV puede discriminar los tres mecanismos de dispersión en la superficie del terreno: difusa, volumen y doble rebote.

M. Huang y S. Jin (2020) [33], realizaron el mapeo y la evaluación de inundaciones empleando un clasificador supervisado y la técnica de detección de cambios a partir del uso de datos SAR Sentinel 1 y ópticos Sentinel 2. Propusieron un nuevo enfoque para mapear rápidamente las regiones inundadas evitando el paso crítico de establecer umbrales. Señalan que las características de retrodispersión y las reglas de variación de diferentes coberturas terrestres son conocimientos previos esenciales para el análisis de inundaciones. Luego, aplicaron clasificaciones supervisadas a las imágenes SAR complementadas con imágenes ópticas, obteniendo una previa a la inundación y otra durante la misma, con lo cual requieren

considerar las mismas clases de cobertura para dar sentido a la detección de cambios entre ambas clasificaciones.

M. Zhang *et al.* (2020) [34], proponen un método que utiliza un procedimiento de umbral automático para generar una clasificación inicial de suelo y agua mediante la integración de la distribución de densidad de probabilidad. A continuación, se emplea un enfoque basado en lógica difusa, que combina los datos de retrodispersión del SAR con otros auxiliares, para refinar la imagen clasificada inicial. Luego, aplican un pos-procesamiento que consiste en la utilización de filtros morfológicos y de extracción, con lo cual se aumenta la homogeneidad de las fracciones de inundación extraídas y se descartan píxeles aislados mejorando la precisión del mapa final.

S. K. Kuntla y P. Manjusree (2020) [35], proponen un algoritmo de clasificación no supervisado para delinear la extensión de la inundación a partir de imágenes SAR. Las áreas inundadas, denominada clase agua, se delimitan mediante segmentación y aplicando umbrales automáticos mediante la técnica de Otsu. Luego, a la clase agua se le aplica un pos-procesamiento utilizando un filtro para depurarla y eliminar ruidos. El algoritmo se probó sobre imágenes del satélite Sentinel 1 en polarización VH, cubriendo un tramo propenso a inundaciones del río Ganges (India).

Según A. Dasgupta *et al.* (2020) [36], las imágenes SAR son a menudo la única fuente de información para mapear la extensión de las inundaciones. En consecuencia, los autores analizaron la confiabilidad de los mapas de inundación basados en SAR para evaluar el rendimiento de un modelo hidrodinámico en la predicción de inundaciones en una región en la India. Las imágenes SAR se convirtieron en mapas probabilísticos de inundaciones combinando las superficies inundadas obtenidas mediante tres técnicas: interpretación visual, umbrales de histogramas y clasificación basada en textura.

J. J. Jennifer *et al.* (2020) [37], señalan que las inundaciones torrenciales ocurridas en agosto de 2018 en la costa suroeste de la India dejaron un récord en la superficie afectada por el evento extremo. Para determinar dicha área aplicaron una clasificación no supervisada basada en el algoritmo de umbral automático de Otsu sobre imágenes SAR del Sentinel 1. También utilizaron el índice de agua de

diferencia normalizado (NDWI) derivado de una imagen óptica Sentinel 2 para diferenciar los cuerpos de agua permanente en la región inundada. Concluyen indicando que el mapa de inundación resultante puede utilizarse para planificar medidas de socorro y evaluación de daños.

2.2 MAPAS DE INUNDACIÓN DE HUMEDALES DESDE IMÁGENES SAR

F. M. Grings *et al.* (2007) [38], sostienen que las imágenes SAR tienen características distintivas que les otorgan un valor significativo para monitorear y mapear inundaciones de humedales. La presencia o ausencia de agua en los humedales puede alterar significativamente la señal detectada de estas áreas dependiendo del tipo de vegetación dominante, su densidad y altura. Según estos autores, los sistemas SAR se han utilizado con éxito para mapear áreas inundadas, sin embargo, aún no existen algoritmos efectivos para estimar ciertos aspectos de la hidrología superficial de los humedales como el agua debajo del dosel vegetal. Los mismos consideran que la recuperación del nivel del agua superficial se puede obtener con el uso de modelos electromagnéticos que aborden correctamente las características estructurales de la vegetación, las diferentes configuraciones SAR (polarización y ángulo de incidencia) y los mecanismos de interacción que tienen lugar entre radar-agua-vegetación.

M. G. Parmuchi *et al.* (2014) [39], utilizaron imágenes multitemporales del satélite Radarsat 1 y un método de clasificación supervisado para mapear el humedal de las islas inferiores del delta del Río Paraná (Argentina). La estrategia de extracción de información se basó en la identificación de los mecanismos de interacción que ocurren entre la señal de radar y el dosel vegetal, considerando diferentes fenologías de la vegetación y condiciones de inundación. Dicha información se utilizó en el diseño de un clasificador supervisado basado en un árbol de decisión para obtener un mapa de cobertura del suelo. De esta investigación se derivan dos conclusiones principales: (1) la necesidad de datos SAR multitemporales adquiridos en diferentes condiciones ambientales para mapear humedales, y (2) las ventajas y la flexibilidad de los clasificadores basados en los mecanismos de interacción.

P. Kandus *et al.* (2014) [40], evaluaron el uso de los datos SAR de Radarsat 1 para la identificación de coberturas del suelo (bosque, juncos, etc.), así como el parámetro del sensor correspondiente al ángulo de incidencia. Analizaron la

retrodispersión de radar de muestras tomadas en sitios conocidos en las islas del delta del Río Paraná (Argentina). La señal de retrodispersión del bosque muestra estabilidad temporal durante el verano y el invierno, sin embargo, la misma se ve fuertemente potenciada por el agua subyacente en el bosque. Se encontró que los retornos de radar cambiaban de una señal atenuada a una dominada por una dispersión de doble rebote. En humedales dominados por juncos, el mecanismo de interacción dominante puede cambiar de doble rebote a reflexión especular debido a la inundación. Durante condiciones normales del nivel del agua, se encontró que la capacidad de diferenciar la vegetación forestal de la herbácea disminuye al aumentar el ángulo de incidencia. Lo mismo ocurre bajo condiciones de inundaciones extremas.

P. J. Moncayo Silva (2017) [41], integro información de microondas activas y pasivas para la estimación de la fracción inundada en humedales fluviales de un sector de la planicie de inundación del delta del río Paraná, indicando que la misma es apropiada para aplicaciones de tipo operativo en el monitoreo de inundaciones. Utilizó imágenes de microondas activas de los radares de apertura sintética Alos Palsar y Cosmo Skymed, aplicando un método de clasificación supervisado de detección de cambios para obtener las áreas inundadas y no inundadas en la zona de estudio. Paralelamente procesó imágenes de sensores de microondas pasivas (AMSRE, AMSR2 y SMOS) con objeto de calcular índices de polarización para la detección de áreas inundadas, no inundadas y cuerpos de agua a escala regional.

J. Zamboni Graosque *et al.* (2019) [42], emplearon el Análisis de Componentes Principales (ACP) para mapear la inundación en el valle de inundación del Río Paraná Medio a la altura de la ciudad de Santa Fe. Utilizaron imágenes Sentinel 1B, Banda C polarización VH, del tipo Interferométrico (IW) Ground Range Detected (GRD). El ACP demuestra ser un método viable para mapear áreas inundables de forma remota dado que, además de la precisión del resultado, el umbral entre agua y no agua se identifica con mayor precisión para blancos horizontales como verticales. La Principal Componente 2 (PC 2) destacó mejor el umbral de intensidad de los píxeles inundados con una precisión del 70%.

En la opinión de D. A. Dinh *et al.* (2019) [43], el delta del Mekong, situado en el sur de Vietnam, es una de las zonas más afectadas del mundo por el cambio climático que provoca el aumento del nivel del mar y frecuentes inundaciones. Por lo

tanto, el mapeo de la misma es esencial para entender su régimen y en consecuencia mitigar sus impactos. Efectuaron un estudio multitemporal, empleando imágenes SAR y ópticas, generando una densa serie temporal de datos que les permitieron analizar los patrones espacio-temporales de las inundaciones en dicha área de interés. Como resultados obtuvieron mapas que proporcionaron una comprensión general de los patrones de inundación del delta y, además, información valiosa para los responsables de la formulación de políticas sobre el territorio.

J. Huth *et al.* (2020) [44], efectuaron un análisis de la dinámica del agua para los humedales del lago Dongting (China), basado en una serie de tiempo de imágenes Sentinel 1. Este estudio se centra en el segundo lago de agua dulce más grande de China y los humedales circundantes, declarados sitio protegido Ramsar. El programa Copernicus de la ESA permite un monitoreo integral con cobertura en toda el área, lo que es especialmente ventajoso para los grandes humedales a los que es difícil acceder durante las inundaciones.

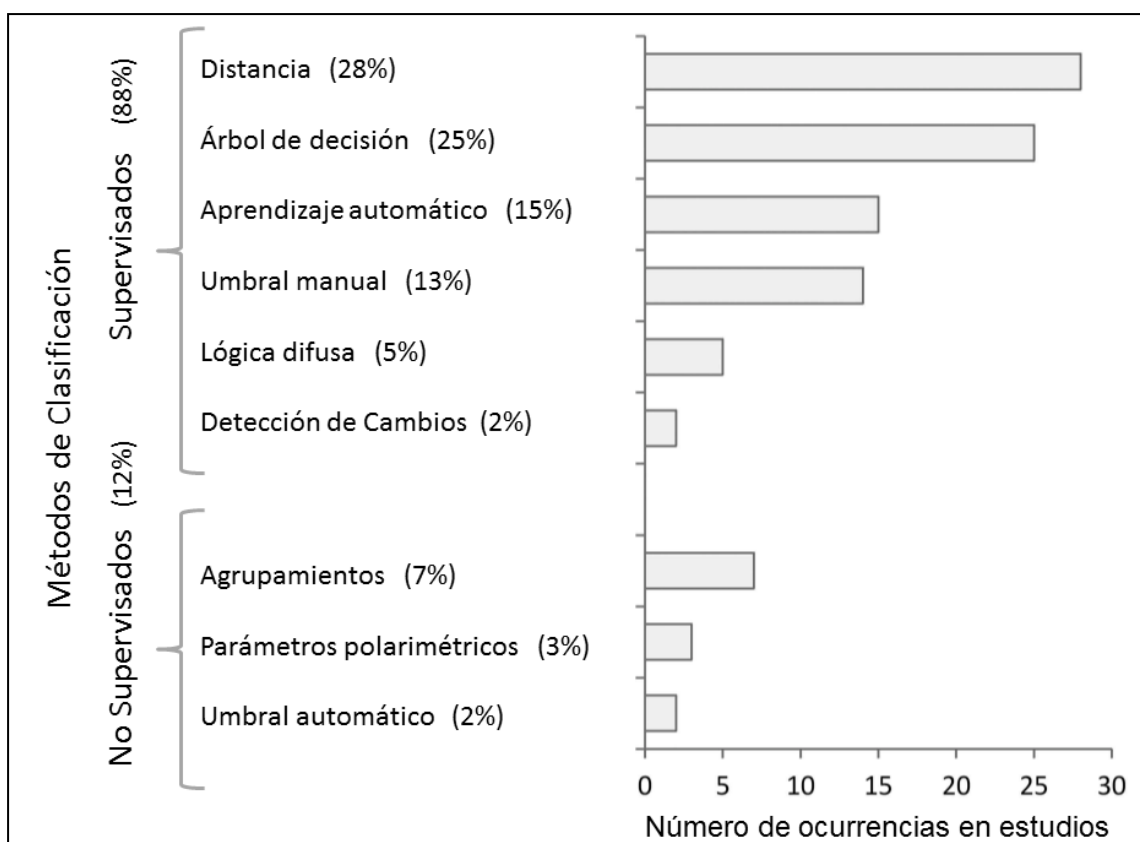
2.3 MÉTODOS PARA DETECTAR VEGETACIÓN INUNDADA

En general los algoritmos para detectar áreas inundadas consideran la baja retrodispersión que se produce en la superficie del agua libre (no cubierta por vegetación), debido a la dispersión especular. Sin embargo, los mismos no tienen en cuenta que la presencia de cultivos en las zonas rurales produce un alto retorno de la señal radar producto del mecanismo de dispersión de doble rebote que involucra el tallo vertical de las plantas con el suelo que puede incrementarse aún más por la presencia del agua de inundación altamente reflectante (N. Pierdicca *et al.*, 2014) [45]. Sin embargo, el aumento del retorno debido al doble rebote es difícil de predecir porque depende de la estructura, geometría y densidad de vegetación, así como de los parámetros del sensor (ángulo de incidencia y polarización) y la altura del agua. Generalmente es más grande con un ángulo de incidencia bajo, debido a la mayor penetración a través del dosel de vegetación, y a la polarización horizontal que presenta una mayor reflexión superficial (Luca Pulvirenti *et al.*, 2011) [46].

La capacidad de los SAR para detectar vegetación inundada (VI), no cubierta por el agua, ofrece un gran beneficio en el monitoreo de inundaciones y humedales. Aunque existen tendencias que sugieren acerca de cuáles son los mejores parámetros del sensor a utilizar (longitudes de onda, polarizaciones y ángulos de

incidencia), todavía no existe acuerdo en cuanto a la aplicación de un determinado tipo de algoritmo de clasificación de imágenes o al uso de información derivada del SAR, dependiendo de los conjuntos de datos y del área de estudio. En ese sentido, se observa una creciente aplicación de métodos de clasificación supervisados y no supervisados para la determinación de la VI. Con base en los avances de los sensores SAR, con respecto a la resolución espacial y temporal, el desarrollo/adaptación de algoritmos robustos para la extracción de VI es aún un desafío que requiere más investigación.

A partir del análisis efectuado por diferentes autores (Xinyi Shen *et al.*, 2019 [1]; V. Tsyganskaya *et al.*, 2018 [47]; F. Cian *et al.*, 2018 [48]) a 83 casos de estudios en los cuales se habían realizado clasificaciones de imágenes SAR para determinar la VI no cubierta por el agua. Se encontró que en tales estudios se habían empleado 100 algoritmos, dado que algunos utilizaron más de uno, de los cuales la gran mayoría correspondía a algoritmos de clasificación supervisados (88%) y en menor medida a los no supervisados (12%), ver Figura 19.




FUENTE: Viktoriya Tsyganskaya *et al.* (2018) [47], adaptado por el autor.

FIGURA 19: Métodos de clasificación supervisado y no supervisado y el número de aplicaciones para la extracción de la vegetación inundada en casos de estudio seleccionados.

MÉTODOS SUPERVISADOS

2.3.1. Método de clasificación supervisado basado en Distancia (28%)

Los métodos de clasificación basados en distancia constituyen la mayoría de los algoritmos de clasificación supervisados aplicados para la extracción de la VI (28 de 100). De estos, se destaca la clasificación de máxima probabilidad (MP) que fue aplicada en 15 de los 28 casos mencionados (53%). El algoritmo supervisado denominado K-Vecinos Más Cercanos (K-VMC) se aplicó 4 veces (14%) y el método del paralelepípedo se utilizó en 3 estudios (11%). Además, 3 de las clasificaciones basadas en distancia utilizaron la distancia de Mahalanobis (11%) y otras 3 aplicaron la distancia Bhattacharyya (11%), ver Figura 20. Debido a su simplicidad, disponibilidad y transparencia estadística (sin caja negra), estos algoritmos basados en distancia son herramientas populares no solo para la clasificación en general, sino también para detectar la VI. Además, se pueden adaptar fácilmente a otros lugares de estudio o conjuntos de datos (J. Martínez y T. Le Toan, 2007) [49]. Sin embargo, X. Na *et al.* (2015) [50] remarcó que tanto la MP como el K-VMC en general no son adecuados para el análisis de datos de alta dimensión lo que puede constituir un inconveniente para la extracción de la VI.



FUENTE: Viktoriya Tsyganskaya *et al.* (2018) [47], adaptado por el autor.

FIGURA 20: Métodos de clasificación basados en Distancia y el número de ocurrencias para la extracción de la vegetación inundada en casos de estudio seleccionados.

2.3.2 Método de clasificación supervisado basado en Árbol de Decisión (25%)

El segundo enfoque más común empleado en las investigaciones para detectar la VI es el Árbol de Decisión (AD) y la Clasificación Jerárquica Basada en Reglas (CJBR) utilizados 25 veces entre los 100 algoritmos analizados. De ese total la mayoría de los estudios, 20 de 25 (80%), aplicaron el AD para la extracción de la VI. Este clasificador supervisado (AD) está bien adaptado para la clasificación de una imagen SAR, porque no asume una distribución particular de densidad de probabilidad de los datos de entrada (N. Baghdadi *et al.*, 2001 [51]; L. Hess *et al.*, 1995 [52]). El algoritmo se basa en reglas jerárquicas que representan umbrales utilizados para dividir iterativamente datos más homogéneos (J. Richards, 2012 [53]), que se pueden refinar fácilmente después de las iteraciones (J. Martinez y T. Le Toan, 2007) [49]. Otra ventaja de los árboles de decisión es su flexibilidad y robustez con respecto a las relaciones no lineales y ruidosas de los datos de entrada (P. Townsend, 2002 [54]; M. Friedl y C. Brodley, 1997 [55]). Esto es un beneficio para la detección de la VI, debido a la diversidad de los datos de entrada aplicados para su determinación. Además, el AD requiere menos tiempo para el entrenamiento en comparación con algoritmos de aprendizaje automático, tales como: la Red Neuronal Artificial (RNA) y las Máquinas de Soporte Vectorial (MSV) (X. Na *et al.*, 2015) [50].

En solo 5 casos de los 25 (20%) se utilizó la CJBR para la extracción de la VI. En estos algoritmos las reglas de clasificación son diseñadas por los usuarios en base a su conocimiento y experiencia y se puede cambiar iterativamente dependiendo de los resultados del proceso de clasificación. Por lo tanto, las características específicas que presenta la VI en las imágenes SAR pueden integrarse sistemáticamente en el conjunto de reglas. La transparencia de este enfoque asegura que este conocimiento pueda ser utilizado como base para otros estudios y toma de decisiones. Además, la CJBR permite agregar nuevos ajustes o conjuntos de datos sin alterar las reglas predefinidas, mientras que los métodos basados en distancia, como la MP, podrían tener que cambiar las reglas de todas las clases debido a la información adicional agregada (T. Evans *et al.*, 2010) [56].

2.3.3 Método de clasif. supervisado basado en Aprendizaje Automático (15%)


En 15 de los 100 algoritmos empleados, se habían utilizado técnicas de aprendizaje automático para la extracción de la VI. La Figura 21 muestra varias técnicas de aprendizaje automático que se aplicaron en los estudios revisados y su

número de ocurrencias. En la mayoría de los casos estudiados, 11 de 15 (73%), se aplicó el método de clasificación de Bosque Aleatorio (BA), el cual es un clasificador que contiene múltiples árboles de decisión y, en consecuencia, las mencionadas ventajas del Árbol de Decisión (AD) también son compartidas por el BA. Al promediar múltiples árboles de decisión, se puede reducir el sobreajuste de cada árbol de decisión (J. Richards, 2012) [53]. Este algoritmo determina eficientemente la contribución de diversos datos a una dada clasificación. Sin embargo, la aplicación de diferentes tipos de datos sin la comprensión de las verdaderas relaciones entre los mismos también puede constituir una desventaja. Por ejemplo, los datos SAR pueden clasificarse como menos importantes que los ópticos debido a una mejor correlación de estos últimos con otras características que permiten determinar la VI. En este caso particular el BA puede ignorar el contexto y establecer la prioridad en los datos ópticos más correlacionados. Por lo tanto, un gran conjunto de datos de referencia es necesario para mitigar una clasificación errónea producida por la variabilidad natural dentro de BA (L. Robertson *et al.*, 2015) [57].

La clasificación supervisada por Máquinas de Soporte Vectorial (MSV) se utilizó en 3 de los 15 casos analizados (20%) que aplicaron aprendizaje automático. La clasificación por MSV tiene como objetivo separar dos clases diferentes determinando los hiperplanos de margen máximo para un dado conjunto de entrenamiento. Las MSV están destinadas a la determinación de la mejor separación lineal entre dos categorías dentro de un nuevo espacio de funciones. Además, la clasificación a partir de las MSV es adecuada para datos de alta dimensión a pesar de que los datos de entrenamiento disponibles sean limitados, lo cual suele ser común cuando se trabaja con VI.

Un solo estudio (7%) aplicó Red Neuronal Artificial (RNA). Este algoritmo de aprendizaje automático está inspirado en la estructura neuronal del cerebro humano (J. Richards, 2012 [53]). Una gran desventaja de este método es el hecho de que se requiere un gran conjunto de muestras para proporcionar una formación eficaz del modelo que, además, podría demandar un elevado tiempo de cálculo. Sin embargo, la RNA ha demostrado varias ventajas para la clasificación de imágenes. Diversas fuentes de datos heterogéneos (por ejemplo, temperatura, intensidades de SAR, nivel de humedad del suelo, etc.) se pueden combinar como aporte. Además, el algoritmo

funciona sin ninguna suposición sobre la distribución de los datos (M. Augusteijn *et al.*, 1998) [58]. Ambas ventajas resultan beneficiosas para la extracción de la VI.



FUENTE: Viktoriya Tsyganskaya *et al.* (2018) [47], adaptado por el autor.

FIGURA 21: Métodos de clasificación supervisado de Aprendizaje Automático y el número de ocurrencias para la extracción de la vegetación inundada en casos de estudio seleccionados.

2.3.4 Método de clasificación supervisado basado en Umbral Manual (13%)

Otro método supervisado para la extracción de la VI es la determinación del umbral manual (UM) utilizado en 13 de los 100 algoritmos aplicados. La definición del valor del umbral es un punto crucial, ya que los parámetros ambientales y del sensor muestran fuertes dependencias mutuas. El umbral para la extracción de la VI tiene que ser determinado individualmente para cada área de estudio y, por lo tanto, no es transferible a otras regiones. Sin embargo, este método proporciona la capacidad de separar entre VI y otras clases rápidamente y sin mucho esfuerzo, por ejemplo utilizando el umbral extraído directamente del histograma.

2.3.5 Método de clasificación supervisado basado en Lógica Difusa (5%)

Se aplicó un enfoque basado en Lógica Difusa (LD) en 5 algoritmos de los 100 analizados. Con esta técnica se intentó integrar diferentes fuentes de información, tales como: datos SAR, diferencia de alturas con áreas abiertas inundadas y relaciones de vecindad entre píxeles. En la teoría clásica de conjuntos, un elemento puede o no pertenecer a un conjunto, a diferencia en un conjunto borroso todos los elementos tienen diferentes grados de pertenencia (J. Buckley y E. Eslami, 2002) [59].

La selección de una función de pertenencia apropiada para construir un conjunto borroso es subjetiva y depende de la tarea y de los datos disponibles. Puede ser un desafío para localizar la VI en zonas de transición entre aguas abiertas y tierras altas en imágenes SAR debido a las variaciones a lo largo del tiempo (Y. Wang, 2004) [60]. La lógica difusa tiene la capacidad de superar estas incertidumbres al describir el aumento de la retrodispersión inducida por la VI utilizando funciones sin umbrales nítidos.

2.3.6 Método de clasificación basado en Detección de Cambios (2%)

Se empleó la Detección de Cambios (DC) en 2 de los 100 algoritmos examinados para determinar áreas con VI. La DC resalta las mudanzas temporales en la cobertura del suelo empleando una imagen como referencia “seca”, adquirida previa a la inundación, y otra tomada durante la misma (L. Giustarini *et al.*, 2016) [61]. Este método compara las intensidades de la retrodispersión (σ_0) antes y durante la inundación, con el objeto de detectar cambios en los píxeles causados por el anegamiento de la superficie. Por lo tanto, se considera que la VI causa una importante diferencia de signo positivo debido a la muy alta respuesta de la señal al regresar al sensor SAR producto del mecanismo de dispersión de doble rebote que involucra al agua de la inundación y a las estructuras vegetales verticales, como tallos o troncos, que actúan como reflectores de esquina. Para detectar este aumento de la retrodispersión de la señal se requiere de la disponibilidad de una imagen anterior a la inundación para ser utilizada como referencia dentro un enfoque de detección de cambios (L. Pulvirenti *et al.*, 2016) [4].

MÉTODOS NO SUPERVISADOS

2.3.7 Método de clasificación no supervisado basado en Agrupamientos (7%)

El agrupamiento de imágenes (cluster) se aplicó en 7 de los 100 algoritmos revisados. Esta técnica se utiliza para identificar relaciones dentro de los datos sin contar con ninguna información previa (conjuntos de entrenamiento) dividiendo los elementos de la imagen en grupos que contienen propiedades iguales o similares (espaciales y/o temporales). El agrupamiento produce una reducción de los elementos a estudiar y, por lo tanto, proporciona una base adecuada para análisis más extensos. Además, constituye una ventaja para la determinación de la VI a partir

de imágenes SAR, dado que el ruido speckle se puede compensar y esto permite considerar las variaciones dentro de la VI así como los cambios fenológicos.

Dentro de este método se emplearon diferentes algoritmos, tales como: K-Medias (se aplicó en 1 de los 7 casos, 14%), K-medoids (1 de 7 casos, 14%) e ISODATA (5 de los 7 casos, 72%). Todos ellos son técnicas iterativas de agrupamiento no jerárquico. Mientras el K-medias usa centroides, que determina a través del promedio entre los puntos de la muestra, para la determinación de los conglomerados, K-medoids emplea medoids, esto es, datos reales que utiliza como centro de los conglomerados, lo que produce que sea más estable ante la presencia de valores atípicos (outliers) en la muestra. Ambos algoritmos calculan un número predefinido de conglomerados, aunque un menor número de conglomerados podrían describir los datos con mayor precisión (H. Park y C. Jun, 2009) [62]. Esta desventaja es superada por ISODATA, que fusiona automáticamente grupos similares y divide grupos que presentan un gran desvío estándar durante el proceso de iteración.

2.3.8 Método de clasif. no superv. basado en Parámetros Polarimétricos (3%)

Las clasificaciones no supervisadas basadas en los parámetros polarimétricos (PP), tales como: Wishart H/α y $H/A/\alpha$, fueron aplicadas en 3 de los 100 algoritmos encontrados. Estas están especialmente diseñadas para datos SAR, requieren el cálculo de los PP, que se puede obtener por descomposición de datos SAR de polarización doble o cuádruple. N. Morandeira *et al.* (2016) [63], aplicaron estas clasificaciones para aumentar la experiencia en la respuesta de retrodispersión de los humedales herbáceos.

2.3.9 Método de clasif. no supervisado basado en Umbral Automático (2%)

De los 100 algoritmos aplicados solo 2 utilizaron el método no supervisado basado en la determinación del Umbral Automático (UA). En estos dos casos se utilizaron el algoritmo propuesto por Otsu (N. Otsu, 1979) [64] y el de Kittler e Illingworth (J. Kittler y J. Illingworth, 1986) [65]. Ambos son métodos que definen automáticamente el umbral en función de la forma del histograma. La principal ventaja de este método es producir una clasificación rápida de las clases claramente separables y, por lo tanto, la creación de una visión general de las clases existentes. Sin embargo, la separación entre VI y no inundada es un desafío debido a la amplia gama de valores dentro de ambas categorías que pueden dar lugar a histogramas

superpuestos. Por lo tanto, la técnica de umbral automático generalmente solo se aplica como parte de una cadena de procesamiento para la extracción de la VI.

2.4 MÉTODOS PARA DETECTAR SUPERFICIES ABIERTAS INUNDADAS

En la actualidad, los algoritmos para detectar inundaciones en áreas abiertas, no obstruidas o cubiertas por vegetación, han logrado una precisión aceptable a partir del uso de imágenes SAR (X. Shen *et al.*, 2019) [1]. Generalmente los mismos buscan regiones con baja retrodispersión de la señal radar, asumiendo así que el agua de la inundación aparece oscura en una imagen SAR, lo cual es una suposición que no siempre es válida. El mapeo de terrenos inundados desnudos o con poca vegetación, o cultivos totalmente sumergidos por el agua, puede resultar una tarea difícil. De hecho, en presencia de un viento significativo se producen olas que aumentan la rugosidad de la superficie del agua provocando que las áreas inundadas puedan aparecer brillantes en la imagen SAR (N. Pierdicca *et al.*, 2014) [45].

La cartografía de superficies abiertas inundadas se puede realizar a través de una clasificación de imágenes empleando tanto el método supervisado como el no supervisado. Los supervisados requieren de la digitalización de las áreas de entrenamiento sobre la imagen SAR. Mediante el uso de tales conjuntos de entrenamiento, los algoritmos de asignación pueden lograr una muy buena precisión sin necesidad de comprender en profundidad la física de la interacción de la señal con los objetos del terreno. Sin embargo, los inconvenientes se relacionan con la generación de conjuntos de entrenamiento lo cual no se puede automatizar y el algoritmo de clasificación tiene dependencia local, es decir, puede no funcionar en otra área de interés. A continuación, se describirán los más utilizados según los antecedentes recopilados para la determinación de áreas abiertas inundadas.

En 55 casos de estudios en los cuales se habían aplicado diferentes métodos de clasificación sobre de imágenes SAR para determinar áreas abiertas inundadas (Z. Shaoqing y L. Xu (2008) [66], X. Shen *et al.* (2019) [1], F. Cian *et al.* (2018) [48]). Se encontró que se habían empleado 67 algoritmos, considerando que ciertos estudios aplicaron más de uno, observándose que los algoritmos de clasificación supervisados representaban un 60% y los no supervisados un 40%, ver Figura 22. Se aprecia un incremento importante en el uso de algoritmos de clasificación no supervisados para

determinar superficies abiertas inundadas (40%) cuando comparado con los utilizados para extraer VI (12%).




FIGURA 22: Métodos de clasificación supervisado y no supervisado y el número de ocurrencias para la determinación de áreas abiertas inundadas en diversos casos de estudio.

MÉTODOS SUPERVISADOS

2.4.1. Método de clasificación supervisado basado en Umbral Manual (22%)

En 15 de los 67 algoritmos empleados, se aplicó un algoritmo basado en la detección del Umbral Manual (UM). Las propiedades reflectantes especulares del agua “libre” no obstruida por vegetación han impulsado el empleo de un umbral por debajo del cual los píxeles se identifican como agua. Es posible que un umbral único no sea constante para grandes superficies inundadas o para toda una franja de una imagen SAR, ya que se ve afectada por la heterogeneidad del entorno, causada por la rugosidad del viento y los parámetros del sistema satelital, entre otros. S. Martinis (2010) [67] demostró la heterogeneidad temporal de la retrodispersión de los cuerpos de agua permanentes, lo que implica la variabilidad temporal del umbral. Esencialmente, un enfoque basado en umbrales necesita tener un histograma de imagen bimodal (de píxeles de agua y no agua) para derivar un umbral que permita la automatización del proceso.

La aplicación del umbral a una imagen SAR que establezca como inundados todos los píxeles con una retrodispersión inferior al mismo, es computacionalmente muy simple, además, proporciona resultados fiables y es ideal para el mapeo rápido de las inundaciones. Sin embargo, se ve afectado por fuentes de error típicas de las imágenes SAR en eventos de inundaciones:

1) perturbaciones atmosféricas; 2) aumento de la dispersión ante la presencia de viento; 3) doble rebote debido a la vegetación emergente; 4) el contenido de humedad del suelo aumenta la retrodispersión del radar y limita la detección de agua en píxeles mixtos; y 5) dependencia de los parámetros del sensor.

Los datos de polarización cruzada (VH y HV) producen una gama más amplia de valores de retrodispersión de superficies de suelo con vegetación en comparación con los de igual polarización (VV y HH), lo que conduce a una posible superposición con los valores bajos de retrodispersión asociados con el agua, causando una clasificación errónea de superficies como inundadas. También, algunos autores indican que las imágenes con polarización VV del satélite Sentinel-1 proporcionan una ligera ventaja al identificar inundaciones (A. Twele *et al.*, 2016) [68], M. Clement *et al.* (2017) [25], S. Aldhshan *et al.* (2019) [28]).

2.4.2 Método de clasif. supervisado basado en Detección de Cambios (21%)

En 14 de los 67 casos encontrados se emplearon algoritmos de Detección de Cambios (DC) para determinar áreas inundadas de agua libre. A diferencia del proceso anterior, que utiliza una sola imagen SAR (inundada), la DC resalta los mudanzas temporales en la cobertura del suelo empleando una imagen como referencia “seca”, adquirida previa a la inundación, y otra tomada durante la misma (L. Giustarini *et al.*, 2016) [61].

Se pueden incluir en la Detección de Cambios todas aquellas técnicas utilizadas para comparar las intensidades de la retrodispersión (σ_0) antes y durante la inundación, con el objeto de detectar cambios en los píxeles causados por el anegamiento de la superficie (M. Santoro y U. Wegmüller, 2012) [69]. Por lo tanto, se considera que las inundaciones causan una importante diferencia negativa debido a la muy baja o prácticamente nula respuesta de la señal al regresar al sensor SAR producto de la dispersión especular que se produce en el agua, en comparación con la mayor retrodispersión del terreno no inundado.

La DC se puede realizar aplicando simplemente operaciones matemáticas básicas tales como la resta o la división de dos imágenes (referencia e inundada) con la misma polarización (K. Green *et al.*, 1994) [70]. Además, en las imágenes SAR las áreas inundadas y los cuerpos de agua permanentes suelen mostrar una retrodispersión más baja que las áreas secas. Por lo tanto, para la detección de inundaciones se puede aplicar una DC comparando una imagen de referencia adquirida antes de la inundación con la imagen propia del evento (J. Reksten *et al.*, 2019 [29]; R. Nasirzadehdizaji *et al.*, 2019 [71]).

Las técnicas de DC pueden mejorar sustancialmente la precisión de los mapas de inundación de superficies abiertas. Para esto, es crucial la selección de una imagen de referencia adecuada que permita detectar los cambios en la retrodispersión debido a las inundaciones y evitar el riesgo de subestimar la extensión del evento. El empleo de una imagen de referencia se puede extender al uso de múltiples referencias secas. Esto es posible en la actualidad debido al Big Data EO que otorga la oportunidad de analizar estadísticamente series largas de imágenes SAR y conseguir identificar una referencia más robusta.

F. Cian *et al.* (2018) [48], desarrollaron un método de mapeo de inundaciones basado en un índice que se calcula utilizando estadísticas de imágenes SAR, específicamente las correspondientes al satélite Sentinel 1 pudiendo extenderse a otros sistemas operativos. El método desarrollado por estos autores para el mapeo de inundaciones se caracteriza por un enfoque novedoso en la detección de cambios, en particular, está basado en un análisis de series multitemporales de imágenes y el cálculo del índice de inundación de diferencia normalizada (NDFI) para destacar las áreas abiertas inundadas en las cuales el agua cubre completamente tanto el suelo como los cultivos.

2.4.3 Método de clasificación supervisado basado en Lógica Difusa (7%)

Se aplicó en 5 algoritmos de los 67 utilizados, enfoques basados en la Lógica Difusa (LD). Con esta técnica (L. Pulvirenti *et al.* (2014) [20], M. Zhang *et al.* (2020) [34]) se integraron diferentes datos auxiliares, tales como: imágenes SAR, imagen del ángulo de incidencia local, un mapa de cobertura del suelo y un imagen óptica. A través de LD, el algoritmo integra diferentes reglas para la detección de áreas oscuras, así como para su clasificación basada en las características radiométricas y

de formas extraídas desde la imagen SAR segmentada y desde los datos auxiliares. El algoritmo produce mapas de clasificación confiables en los cuales se pueden distinguir las áreas de agua libre inundadas.

2.4.4 Método de clasificación supervisado basado en Distancia (6%)

En tan solo 4 de los 67 algoritmos empleados se aplicaron los basados en Distancia. En todos estos casos se aplicó el algoritmo de clasificación de máxima probabilidad (MP) para obtener el mapa de inundación de superficie de agua libre. Como ya fue indicado estos algoritmos basados en distancia son herramientas de fácil aplicación y siempre disponibles en los programas de procesamiento de imágenes (S. Solbø e I. Solheim (2005) [17]; A. Benoudjit y R. Guida (2019) [27]).

2.4.5 Método de clasif. supervisado basado en Aprendizaje Automático (2%)

Solo se observó un caso de los 67 algoritmos empleados, en el cual se aplicó la técnica de aprendizaje automático utilizándose el Bosque Aleatorio (BA) para la extracción de la superficie de agua libre (J. Reksten *et al.* (2019) [29]). Este es un algoritmo que utiliza el promedio de múltiples árboles de decisión, con lo cual se puede reducir el sobreajuste que puede llegar a producir cada árbol de decisión individualmente (J. Richards, 2012) [53]. Este algoritmo determina eficientemente la contribución de diversos datos a una dada clasificación. Sin embargo, puede llegar a ignorar el contexto y dar prioridad a datos más correlacionados. Por lo tanto, un gran conjunto de datos de referencia es necesario para mitigar una clasificación errónea producida por la variabilidad natural dentro de BA (L. Robertson *et al.*, 2015) [57].

2.4.6 Método de clasificación supervisado basado en Análisis visual (2%)

También, se encontró un solo caso de los 67 en el que se aplicó la técnica de Análisis Visual (AV). Como se discutió anteriormente, los resultados del mapeo de las superficies inundadas derivados de las imágenes SAR se ven afectados por muchas fuentes de error, que difícilmente pueden ser eliminadas por la mayoría de los algoritmos. La inspección visual y la edición manual ayudan a digitalizar las fracciones inundadas (A. Dasgupta *et al.*, 2020) [36]. Dado que la edición manual requiere un importante esfuerzo que demanda mucho tiempo, no se lo puede utilizar para la respuesta rápida a desastres por inundaciones, especialmente durante eventos de inundaciones consecutivas.

MÉTODOS NO SUPERVISADOS

2.4.7 Método de clasificación no supervisado basado en Segmentación (19%)

Se observaron 13 de los 67 casos en los cuales se utilizó el algoritmo de segmentación de imágenes. En este método, y a diferencia de lo que sucede con la determinación del umbral basado en píxeles, las técnicas de segmentación de imágenes agrupan píxeles homogéneos conectados en áreas que pueden proporcionar información a nivel del objeto, es decir, a un nivel superior al del píxel y, por lo tanto, son menos sensibles al speckle porque utilizan información morfológica en lugar de solo información radiométrica.

La segmentación de una imagen SAR ayuda a identificar regiones correspondientes a diferentes clases de cobertura del suelo, como campos, áreas urbanas, masas de agua, etc. Por lo tanto, la hipótesis del método de segmentación es que toda la imagen se compone de regiones de retrodispersión relativamente uniformes, que muestran cambios locales en sus bordes. A diferencia de los enfoques de filtrado, la segmentación no intenta reconstruir el valor de retrodispersión de cada píxel, sino que se centra en la descripción explícita de las estructuras de la imagen (L. Giustarini *et al.* (2015) [22]).

El método de Contorno Activo (CA) permite una cierta cantidad de heterogeneidad en la retrodispersión proveniente de un cuerpo de agua e incorpora métricas morfológicas, como curvatura y tensión. S. Martinis (2010) [67] han aplicado la segmentación Orientada a Objetos (OO) para reducir las falsas alarmas y el speckle. Los mismos autores compararon los algoritmos de CA con el OO y concluyeron que este último delimitaba las áreas de agua con mayor precisión que el primero, que tiende a sobreestimar su extensión. L. Pulvirenti *et al.* (2014) [19] desarrollaron un método de segmentación de imágenes que consiste en operadores de dilución y erosión para eliminar grupos aislados de píxeles de agua y pequeños agujeros en cuerpos de agua, que se cree que son causados por speckle. L. Giustarini *et al.* (2015) [22] emplearon otra clase de algoritmo de CA basado en Crecimiento por Región (CR) para extender las áreas de inundación a los píxeles de agua detectados. Este último algoritmo (CR) comienza seleccionando píxeles (semillas) y luego continua absorbiendo píxeles vecinos homogéneos hasta que no existan más píxeles similares en la vecindad. En este esquema un contorno es deformado iterativamente para localizar el borde de un objeto, guiado por un criterio

estadístico, utilizando la distribución Gamma para caracterizar los datos. El problema de este algoritmo es que la distribución Gamma no modela apropiadamente los datos SAR provenientes de regiones muy heterogéneas (I. Belmonte y S. Caamaño, 2009) [18].

2.4.8 Método de clasif. no supervisado basado en Umbral Automático (15%)

De los 67 algoritmos aplicados 10 utilizaron el método no supervisado basado en la determinación del Umbral Automático (UA). H. Cao *et al.* (2019) [31], propusieron un algoritmo de umbral no paramétrico de búsqueda las para imágenes SAR que presentan un histograma de distribución gaussiana bimodal. Varios autores emplearon la técnica de Otsu para obtener el umbral automáticamente en función de la forma del histograma (S. Kuntla y P. Manjusree, 2020 [35]; J. Jennifer *et al.*, 2020 [37]). El método del UA produce rápidamente una clasificación de las superficies abiertas inundadas a las cuales luego se les aplica un pos-procesamiento utilizando un filtro para depurarlas y eliminar ruidos.

2.4.9 Método de clasif. no superv. basado en Coherencia Interferométrica (4%)

Se utilizaron 3 algoritmos de los 67 encontrados, que emplearon la Coherencia Interferométrica (CI) para derivar las superficies de agua libre. A. Jacob *et al.* (2020) [72], investigaron y demostraron la idoneidad de la CI derivada de las imágenes Sentinel-1 para el mapeo de las áreas inundadas. Indicaron que la coherencia interferométrica y la intensidad demuestran ser observables complementarios, lo que aumenta las precisiones generales empleando una estrategia combinada. Según A. Giraldez (2003) [73], la interferometria introduce el concepto de coherencia como nuevo parámetro, que puede ser muy útil en la clasificación de la cobertura de la superficie. La coherencia se puede utilizar para conocer en donde se han producido cambios en la cobertura del suelo entre la toma de ambas imágenes complejas (SLC). Una coherencia cercana a 1 indicará la inexistencia de cambios en un dado píxel de ambas imágenes y una próxima a 0 mostrará lo contrario (S. Cloude, 2004 [74]). En la opinión de H. Del Valle (2017) [75] la CI ha sido empleada con éxito como un parámetro de clasificación de la cobertura del suelo, señalando que una CI muy baja indica usualmente agua, una CI media revela vegetación en crecimiento o en movimiento y una CI alta muestra áreas urbanas u otras características estables.

2.4.10 Método de clasif. no superv. basado en Parámetros Polarimétricos (2%)

Se encontró un solo caso de los 67 que aplicó una clasificación no supervisada basadas en los parámetros polarimétricos (PP), tales como: Wishart H/α y $H/A/\alpha$. S. Cloude y E. Pottier (1997) [76], propusieron un algoritmo para identificar de manera no supervisada los mecanismos de dispersión polarimétrica en el plano Entropía-Alpha ($H-\alpha$). La idea clave es que la H surge como una medida natural del desorden inherente a los datos de dispersión SAR y α puede usarse para identificar el mecanismo de dispersión dominante. K. Ji e Y. Wu (2015) [32], sostienen que la polarización dual es un modo operativo típico de los satélites SAR y, por lo tanto, proponen una descomposición de Cloude-Pottier modificada para investigar el rendimiento de las imágenes SAR de polarización dual (HH y VV) en la extracción de los mecanismos de dispersión, en particular el mecanismo de dispersión especular propio de las superficies de aguas abiertas.

2.5 VALIDACIÓN DE LA INFORMACIÓN DERIVADA DE IMÁGENES SAR

Una manera de evaluar la exactitud de los mapas temáticos que se obtienen a partir de las imágenes satelitales SAR es estableciendo qué porcentaje de la cartografía ha sido correctamente clasificado al compararlo con la verdad del terreno. Además, no sólo se procede a valorar la exactitud del mapa en su conjunto, sino que se determina la exactitud de cada clase en particular. Se calcula para ello la matriz de error de la clasificación, también conocida como matriz de confusión.

Matriz de Error

La matriz de error representa los conflictos que se presentan entre las diferentes clases de un mapa temático, las columnas representan la información de referencia (verdad del terreno) y las filas indican el resultado de la clasificación que se evalúa. La diagonal de esta matriz expresa el número de coincidencias que se produce entre las categorías derivadas del mapa y la verdad del terreno. Por otro lado, los marginales indican los errores de asignación, conocidos como errores de omisión y comisión. Los residuales en columna indican clases de la cobertura real del terreno que no se incluyeron en el mapa (errores de omisión), mientras los residuales en filas implican categorías del mapa que no se ajustan a la realidad (errores de comisión) (S. Aronoff, 1982 [77]; M. Story y R. Congalton, 1986 [78]).

También, se consideran dos índices para medir la precisión de la clasificación, uno de ellos expresa la relación entre el número de píxeles correctamente asignados sobre la diagonal principal y el total de los que participan en la evaluación, se lo denomina índice de fiabilidad global del mapa. Al segundo, se lo conoce como índice Kappa, y el mismo expresa que las coincidencias entre las categorías clasificadas por un dado método y la verdad del terreno, se producen por un correcto funcionamiento del algoritmo y no son debidas al azar o la casualidad.

Las matrices de confusión tienen la capacidad para identificar los problemas que se producen en la asignación de las categorías por parte del algoritmo de clasificación; de esta forma, se conoce la precisión conseguida para cada una de las clases, así como los principales conflictos entre ellas. En la Figura 23 se puede observar la estructura de la misma.

		Referencia				Total	Exactitud Usuario	Error Comisión
		Clase 1	Clase 2	Clase 3	Clase n			
Clasificación	Clase 1	X_{11}				X_{1+}	X_{11}/X_{1+}	$1-X_{11}/X_{1+}$
	Clase 2		X_{22}			X_{2+}	X_{22}/X_{2+}	$1-X_{22}/X_{2+}$
	Clase 3			X_{33}		X_{3+}	X_{33}/X_{3+}	$1-X_{33}/X_{3+}$
	Clase n				X_{nn}	X_{n+}	X_{nn}/X_{n+}	$1-X_{nn}/X_{n+}$
	Total	X_{+1}	X_{+2}	X_{+3}	X_{+n}	$\sum X_{ij}$		
	Exactitud Productor	X_{11}/X_{+1}	X_{22}/X_{+2}	X_{33}/X_{+3}	X_{nn}/X_{+n}			
Error Omisión	$1-X_{11}/X_{+1}$	$1-X_{22}/X_{+2}$	$1-X_{33}/X_{+3}$	$1-X_{nn}/X_{+n}$				

Píxeles bien clasificados
 Errores de omisión
 Errores de comisión

FUENTE: Emilio Chuvieco, 2007 [79]

FIGURA 23: Estructura de la matriz de error o de confusión.

En los antecedentes analizados se observó que pocos estudios proporcionaron una comparación de las precisiones obtenidas en los resultados a partir de la aplicación de diferentes métodos de clasificación, los cuales se implementaron en base a los mismos conjuntos de datos SAR. A continuación, se indican los estadísticos de rendimiento, derivados de la matriz de confusión, que fueron utilizados para demostrar las precisiones alcanzadas por varios de los

algoritmos empleados. Los mismos fueron: Exactitud del Productor (EP), Exactitud del Usuario (EU) y los índices de fiabilidad global y Kappa.

Y. Chen *et al.* (2014) [80] compararon las precisiones de los resultados alcanzados por tres algoritmos de clasificación, utilizados para determinar la VI en humedales, a partir del uso de las exactitudes del productor (EP) y del usuario (EU). Emplearon un algoritmo no supervisado basado en parámetros polarimétricos: clasificación Wishart (EP: 95 %, EU: 73 %) y dos supervisados: K-Vecinos Más Cercanos (EP: 94 % y EU: 78 %) y Árbol de Decisión (EP: 94 % y EU: 80 %). En otro estudio, Na *et al.* (2015) [81], alcanzaron los siguientes resultados en la determinación de bosques y humedales herbáceos inundados aplicando dos algoritmos de clasificación supervisados: para el Bosque Aleatorio (EP: 83% y EU: 81%) que superaron los resultados del K-Vecinos Más Cercanos (EP: 35% y EU: 65%). J. Betbeder *et al.* (2014) [82], utilizaron el índice kappa para indicar la precisión para un dado de estudio que incluye tres algoritmos de clasificación supervisados: K-Vecinos Más Cercanos (Kappa = 0,74), Árbol de Decisión (Kappa = 0,66) y Máquinas de Soporte Vectorial (Kappa = 0,85). Además, de alcanzar un mayor índice Kappa este último algoritmo obtuvo también una EP: 90% y una EU: 75%.

Otros autores, emplearon como verdad del terreno una imagen óptica y al índice de fiabilidad global para validar los resultados obtenidos a partir de la aplicación de diferentes algoritmos de clasificación sobre imágenes SAR. Tal el caso de M. Clement *et al.* (2017) [25] quienes validaron los mapas de áreas abiertas inundadas con una imagen óptica Sentinel-2, obteniendo un índice de fiabilidad global del 97%. A. Benoudjit y R. Guida (2019) [27], emplearon un clasificador supervisado para mapear inundación con imágenes SAR. Obtuvieron un índice de fiabilidad global del 90%. H. Cao *et al.* (2019) [31], utilizaron para la detección de inundaciones un método de clasificación no supervisado que emplea datos SAR. Los resultados obtenidos los aprobaron a través de una imagen óptica Landsat 8 obteniendo un índice de fiabilidad global de la clasificación del 99%. Algunos autores (M. Zhang *et al.*, 2020 [34]; S. Kuntla y P. Manjusree, 2020 [35]), propusieron un método de clasificación no supervisado basado en Umbral Automático. Los resultados alcanzaron un índice de fiabilidad global que varía de 91% a 97% y un coeficiente Kappa que va entre 0,89 y 0,95.

2.6 RESUMEN DE LOS MÉTODOS DE CLASIFICACIÓN

2.6.1 Revisados en el Estado del Arte

Del análisis de los métodos de clasificación empleados para la determinación de la vegetación inundada (VI) se observa que predomina ampliamente el uso de los algoritmos de clasificación supervisados (88%) contra los no supervisados (12%). Entre los supervisados se destacan los algoritmos de distancia (28%), árbol de decisión (25%) y Aprendizaje Automático (15%). El primero se enfatiza por su simplicidad y disponibilidad en la mayor parte de los programas de procesamiento de imágenes y, además, se adaptan fácilmente a múltiples datos de entrada y diversas áreas de estudio. Sin embargo, no son tan adecuados para datos de alta dimensión. En cuanto al segundo algoritmo basado en Árbol de Decisión, presenta como principal ventaja que no asume una distribución particular de probabilidad de los datos de entrada y los usuarios pueden establecer reglas de clasificación, en base a sus experiencias, que se pueden cambiar iterativamente. El tercer algoritmo supervisado es el de Aprendizaje Automático en particular el denominado Bosque Aleatorio, el cual presenta las mismas ventajas del Árbol de Decisión dado que está formado por múltiples árboles de decisión con el aditamento que al promediar los mismos se reduce el sobreajuste de cada uno de ellos. Sus desventajas están relacionadas a la demanda de un gran conjunto de datos de entrada para establecer las reglas de clasificación y mayor tiempo para efectuar el entrenamiento.

En cuanto al estudio de los algoritmos empleados para la determinación de Superficies Abiertas Inundadas (SAI) se aprecia una disminución en el uso de los algoritmos de clasificación supervisados (60%) dado un fuerte incremento de los no supervisados (40%). Esto se puede deber al hecho que la determinación de las SAI es más simple que la VI, debido a la dispersión especular que se produce en las primeras lo cual generalmente provoca un histograma bimodal que facilita la clasificación de las áreas abiertas inundadas. Entre los métodos supervisados sobresalen los algoritmos de Umbral Manual (22%) y Detección de Cambios (21%). El primero de estos es fácilmente aplicable cuando la imagen presenta un histograma bimodal que permite establecer el umbral entre las clases agua (inundado) y no agua, lo cual proporciona resultados fiables y permite un rápido mapeo de las inundaciones. No obstante, existe variabilidad espacial del umbral para grandes superficies inundadas debido a la rugosidad producida por el viento y a la heterogeneidad del terreno. En el caso del algoritmo de Detección de Cambios este resalta mudanzas

temporales que se producen entre una imagen de referencia (o una serie) previa a la inundación y otra imagen durante la misma. Entre sus mejorías se destaca la aplicación de operaciones aritméticas simples (resta o división) sobre las imágenes lo cual facilita su implementación a través de índices de inundación.

También, sobresalen en la determinación de las SAI los métodos no supervisados, entre ellos la Segmentación (19%) y el Umbral Automático (15%). El primero de ellos presenta la posibilidad de identificar regiones de retrodispersión homogéneas, proporcionando información a nivel de objeto siendo, por lo tanto, menos afectadas por el speckle. La principal desventaja está relacionada a la detección de SAI heterogéneas debido a la presencia de viento que reduce la dispersión especular. El segundo método no supervisado más utilizado presenta la ventaja de definir automáticamente el umbral en un histograma bimodal produciendo rápidamente una clasificación de las SAI. El problema aparece cuando se tiene un histograma superpuesto que produce confusión entre las clases. En el Anexo I se presentan dos tablas donde se resumen las principales ventajas y desventajas de los métodos de clasificación supervisados y no supervisados para detectar VI y SAI.

2.6.2 Utilizados en este Trabajo

A partir del análisis de los métodos de clasificación, supervisados y no supervisados, revisados en el estado de arte para extraer tanto la VI como las SAI, se decidió aplicar en esta investigación el método de clasificación supervisado denominado Umbral Manual (UM) por ser el más utilizado para la determinación de las SAI (22%) y, también, bastante empleado para la extracción de la VI (13%). El mismo presenta la ventaja de ser fácilmente aplicable cuando la imagen presenta un histograma bimodal que permite establecer el umbral entre las clases agua (SAI) y no agua, proporcionando resultados confiables y permitiendo un rápido mapeo de la inundación. También, en el caso de la VI es factible determinar un umbral a partir del incremento de la retrodispersión de la señal producido por el mecanismo de dispersión de doble rebote.

El segundo método de clasificación supervisada seleccionado es la Detección de Cambios (DC) la cual resalta las mudanzas temporales que se producen entre una imagen adquirida previa a la inundación y otra tomada durante la misma. Este algoritmo es empleado ampliamente entre los que se utilizan para la detección de las

SAI (21%) y muy poco utilizado para la VI (2%). No obstante, se lo aplicó dada la posibilidad de poder utilizar diversos índices para derivar tanto la VI como las SAI y, también, por la oportunidad de emplear tanto una imagen de referencia, como una serie de imágenes para establecer una referencia promedio.

En relación al tercer método de clasificación no supervisado aplicado, correspondiente a los Parámetros Polarimétricos (PP) derivados de la técnica PolSAR, se observó en la revisión bibliográfica efectuada que los mismos son escasamente utilizados para determinar las SAI (2%) y la VI (3%). Sin embargo, se los consideró dado la ventaja única que presentan para extraer los mecanismos de dispersión presentes en el área de estudio, tales como: especular y de doble rebote.

También, en el caso del cuarto método aplicado de clasificación no supervisado denominado Coherencia Interferométrica (CI) obtenido a partir de la técnica InSAR, se observó en la búsqueda de antecedentes que el mismo es muy poco empleado para determinar las SAI (4%) y no se encontró ningún trabajo en el cual se lo utilice para detectar la VI. No obstante, se recurrió al mismo dado que es específico de las imágenes SAR en formato SLC. Además, permite conocer en donde se han producido cambios en la cobertura del suelo entre la toma de dos imágenes complejas (SLC), una previa al evento y la otra concomitante al mismo. Una CI muy baja (0) indica usualmente agua, una CI media (0,5) revela vegetación en crecimiento o en movimiento y una CI alta (1) muestra áreas urbanas u otras características estables.

Finalmente, a partir de la revisión de los diversos casos de estudio encontrados, se escogió a la matriz de error para la validación de los resultados obtenidos por los distintos métodos de clasificación empleados en este trabajo (UM, DC, PP y CI). De la misma se utilizaron los parámetros de rendimiento, tales como: Exactitud del Productor (EP), Exactitud del Usuario (EU) y los índices de fiabilidad global y Kappa. En particular fueron estos dos últimos índices los elegidos para definir el método de clasificación más adecuado en la determinación de la VI y las SAI en el área de estudio.

3. FUNDAMENTACIÓN TEÓRICA

3.1 INTERACCIÓN ENTRE LA SEÑAL SAR y LOS CUERPOS DE AGUA

Los sistemas SAR miden la retrodispersión de las microondas desde la superficie de la Tierra, es decir, la porción de la señal enviada que se dispersa hacia el sensor. Ellos son insensibles a la cobertura nubosa y pueden medir de día y de noche ya que poseen su propia fuente de energía. Además, estos sistemas presentan alta resolución espacial (decenas de metros) y una temporal intermedia (semanal).

Al interactuar con el terreno, lo hacen principalmente con aquellos componentes del tamaño de su longitud de onda, en este caso del orden de centímetros. Los componentes del terreno que determinan la reflectividad al radar son su geometría, rugosidad y humedad. La alta sensibilidad a la humedad del suelo y las inundaciones se debe al alto contraste entre las propiedades dieléctricas del agua (80) y del suelo seco (5) que se aprecia en la banda L de 1,26 GHz (W. Rees, 2005) [83].

Para S. Martinis (2010) [67], la detección de cuerpos de agua en las imágenes SAR depende, por un lado, del contraste entre el agua y el terreno circundante, lo cual es influenciado por las características de rugosidad de la superficie del agua afectada por el viento, y, por otro, de los parámetros del sistema, como la longitud de onda, el ángulo de incidencia y la polarización, características que en conjunto determinan el mecanismo de interacción entre la onda y la superficie del agua.

Debido a la alta constante dieléctrica del agua las microondas no consiguen atravesarla por lo cual la retrodispersión depende de la rugosidad superficial de la misma. En un caso ideal, un cuerpo de agua abierto puede ser modelado como una superficie perfectamente lisa con una alta constante dieléctrica, que actúa como un reflector especular que dirige la radiación de microondas incidente lejos del sensor SAR en la dirección contraria al mismo, por lo cual la retrodispersión es nula y usualmente se aprecia en color negro en la imagen (Figura 24). Estas áreas con agua contrastan fuertemente con la mayor retrodispersión de las áreas circundantes más rugosas, que se caracterizan por un aumento en la reflexión difusa de superficie provocando distintos tonos de grises (D. Mason *et al.*, 2007) [84].




FIGURA 24: Dispersión especular en el agua (izq.) y difusa desde el suelo (der.).

También la polarización juega un papel importante en la detección de zonas de aguas abiertas. Para la identificación de anegamientos en áreas donde el agua ha cubierto todo tipo de coberturas (suelo y vegetación), es conveniente utilizar la polarización HH. Dicha polarización proporciona la mejor discriminación entre el agua y otras cubiertas del suelo ya que interactúa menos con la vegetación que usualmente tiene estructura vertical y, además, es menos sensible a la rugosidad del agua originada por el viento. Sin embargo, la dispersión especular también se registra al emplear las otras polarizaciones VV, VH y HV (M. Edrosa, 2011) [85].

3.2 INTERACCIÓN ENTRE LA SEÑAL SAR y LA VEGETACIÓN NO INUNDADA

En el caso de la vegetación, en un período sin inundación, el tipo de interacción que se presenta entre ésta y la señal de microondas depende principalmente de la longitud de la onda transmitida en relación con el tamaño de las estructuras de la vegetación (hojas, tallos, troncos, etc.). También influyen la orientación de estos elementos con respecto a la polarización de la onda incidente y la humedad de la planta. Esta última determina la penetración de la onda (a mayor humedad menor penetración y viceversa) y consecuentemente su grado de dispersión (a mayor humedad se incrementa la retrodispersión de la señal hacia el sensor y lo contrario cuando está seca o con déficit de agua).

De esta manera, longitudes de onda menores (banda X) interactúan principalmente con los estratos superiores de la vegetación, las longitudes intermedias (banda C) lo hacen con el interior del cuerpo o volumen del dosel y las longitudes de onda más larga (L) con los estratos inferiores de las plantas, pudiendo en algunos casos hasta interactuar con el suelo o inclusive con el subsuelo, siempre que los mismos estén en condiciones secas (Ulaby *et al.*, 1981) [16], ver Figura 25.




FIGURA 25: Dispersión de la señal SAR desde distintos estratos de la vegetación en función de la longitud de onda empleada (Banda).

3.3 INTERACCIÓN ENTRE LA SEÑAL SAR y LA VEGETACIÓN INUNDADA

El retorno de la señal de la vegetación inundada es muy variable según la condición de inundación particular y fuertemente dependiente de la longitud de onda del sistema y de la estructura y densidad del dosel. También depende del ángulo de incidencia y la polarización (J. Richards *et al.*, 1987) [86].

A. Twele *et al.* (2016) [68] analizaron la sensibilidad de los datos SAR multitemporales y multifrecuencia a diferentes coberturas terrestres y concluyeron que la banda X solo se puede utilizar para detectar inundaciones debajo de la vegetación cuando esta es escasa (poco densa) o en el caso de un bosque caducifolio cuando el mismo está sin hojas durante el período de otoño-invierno. Por otro lado, la banda L, aunque se caracteriza por una mayor penetración del dosel, tiene un rango radiométrico muy amplio de la retrodispersión, que también disminuye la fiabilidad de la clasificación.

En la opinión de M. Salvia (2010) [87], las microondas emitidas por el sensor del SAR, dado su capacidad para atravesar el dosel, ofrecen la posibilidad de mapear las inundaciones por debajo de la vegetación. Esto ocurre por el aumento de la retrodispersión debido al mecanismo de interacción (señal - blanco) de doble rebote entre la vegetación y el agua de la inundación que la cubre parcialmente (Figura 26).




FIGURA 26: Dispersión difusa desde el suelo no inundado (izq.) y de doble rebote (agua – tronco) en el inundado (der.).

El ángulo de incidencia tiene un impacto importante en la capacidad de detectar la inundación por debajo de la vegetación. Varios estudios indican que ángulos de incidencia más empinados ($<35^\circ$) son preferibles para distinguir vegetación inundada de no inundada. Por el contrario, con ángulos de incidencia más rasantes ($>35^\circ$) el camino recorrido por las microondas en el dosel es mayor y por eso se produce su atenuación con pérdida en la identificación de las fracciones anegadas. Esta generalización se puede atribuir a una longitud de recorrido más corta a través del dosel, en el caso de los ángulos empinados, aumentando la transmisividad de la señal en el mismo y dejando más energía para la interacción de doble rebote entre los tallos y el agua. Las señales de ángulo de incidencia más rasante interactúan en mayor medida con el dosel, lo que da como resultado un incremento de la dispersión de volumen. La mejor discriminación entre vegetación inundada y no inundada es factible utilizando imágenes adquiridas con ángulos de incidencia entre $27,5^\circ$ y $33,5^\circ$ (F. Grings *et al.*, 2006) [88].

Algunos estudios indican una preferencia hacia polarizaciones simples (HH o VV) para la separación de la vegetación inundada y la no inundada. Según estos, la proporción de retrodispersión de vegetación inundada y no inundada, es superior en la HH que en la VV. Además, sostienen que la retrodispersión es generalmente muy débil para la polarización cruzada (HV o VH) ya que la depolarización no se produce para reflectores de doble rebote (F. Grings *et al.*, 2006) [88].

3.4 INTERACCIÓN ENTRE LA SEÑAL SAR y CIERTOS CULTIVOS

En el caso particular de los cultivos con estructura vertical o casi vertical, como el maíz, y considerando las bandas C y L, el mecanismo de interacción

dominante en períodos sin inundación es la dispersión de volumen. Por el contrario, durante una inundación, cuando del agua cubre parcialmente el tallo de las plantas, el mecanismo de interacción dominante cambia al de doble rebote agua-tallo para ambas frecuencias C y L (M. Salvia *et al.*, 2010) [89].

Este cambio en el mecanismo de interacción (de volumen a doble rebote) que se produce en ciertos cultivos, cuando sucede una inundación, se puede explicar porque al aumentar la altura del agua se reduce la porción emergida de las plantas del cultivo, provocando primero una disminución de la atenuación por la vegetación y consecuentemente un aumento de la señal retrodispersada por la dispersión de doble rebote agua-tallo. Esto se produce hasta que la altura del agua es tal que se empieza a equiparar el doble rebote agua-tallo con la reflexión especular de la superficie del agua, punto a partir del cual una mayor altura del agua provoca una disminución de la señal retrodispersada por el aumento relativo de la dispersión especular sobre el doble rebote (Banda C), mostrado en la Figura 27. A su vez, la Figura 28 muestra la situación comentada para el caso del cultivo de maíz en el área de estudio.

En Banda L en cambio, la atenuación por las plantas de maíz es insignificante, por lo tanto, un aumento en la altura del agua dentro de ambientes como un maizal provoca directamente una disminución en la retrodispersión de doble rebote agua-tallo por el aumento en la dispersión especular.




FIGURA 27: Dispersión dominante en un cultivo: de volumen cuando no está inundado (izq.), doble rebote lo está parcialmente (centro) y especular completamente inundado (der.).



FIGURA 28: Cultivo de maíz en diversas situaciones: no inundado (izq.), parcialmente anegado (centro) y completamente cubierto por el agua (der.).

La Figura 32 arriba, muestra el caso particular del cultivo de maíz en el área de interés. Se puede observar, a la izquierda de la misma, un lote de maíz no inundado previo al evento climático, en donde y según lo explicado previamente, prevalece el mecanismo de dispersión de volumen. En el centro de dicha figura, se observa un lote inundado parcialmente, menos de la mitad de la altura de la planta (entre 50 y 80 cm de agua), que provoca la dispersión doble rebote agua tallo. Por último, a la derecha se puede ver un lote inundado casi completamente (altura del agua mayor a 100 cm) que da lugar a una prevalencia de la dispersión especular desde el agua.

4. MATERIALES Y MÉTODO

4.1 MATERIALES

4.1.1 Datos de campo

Se obtuvo información de relevamientos de campo realizados por personal del INTA Rafaela, sobre el área de estudio, los días 3, 11 y 12 de enero de 2017. En los mismos se tomaron registros fotográficos, descripción de la ubicación de lotes rurales anegados y tipo de cobertura vegetal presente o ausencia de la misma (rastrajo). La Figura 29 muestra la ubicación de los lotes en donde se adquirieron las muestras en el área de estudio superpuestos a la imagen óptica Sentinel 2 del 10/01/2017.




FIGURA 29: Localización de los puntos de muestreo en el área de estudio (amarillo) superpuestos a la imagen Sentinel 2 (RGB-118a5) del 10/01/2017.

A continuación, la Tabla 3 muestra los 19 puntos de muestreo tomados, con su identificador, ubicación (coord. Gauss Kruger - Faja 5) y el tipo de cobertura determinada en campo. Se observa que 12 de los mismos (color azul) estaban completamente inundados pudiendo identificar en algunos casos el tipo de cobertura

que el agua cubría, tal el caso de lotes con soja o con rastrojo de trigo. En otros 3 puntos (color verde) el agua no llegaba a sobrepasar las plantas de maíz quedando inundada aproximadamente hasta la mitad de su altura. En el caso de los 4 puntos faltantes (color anaranjado), los mismos se tomaron sobre lotes de soja y sorgo no inundados, pero con la presencia de charcos de agua dentro de los mismos.

TABLA 3: Puntos de muestreo tomados en el área de estudio en enero de 2017.

Identif.	Localización (Gauss Kruger - Faja 5)	Cobertura
1	5344894.54; 6543619.64	Agua
2	5344849.87; 6543292.05	Maíz inundado parcialmente
3	5345257.86; 6543530.30	Agua
4	5345165.54; 6543244.40	Agua
5	5347449.71; 6543470.73	Maíz inundado parcialmente
6	5343166.72; 6543648.47	Agua
7	5330957.06; 6546224.90	Soja con charcos de agua
8	5329658.22; 6546717.67	Sorgo con charcos de agua
9	5318739.93; 6560135.57	Agua sobre Soja
10	5319399.82; 6564704.85	Agua
11	5319036.55 6561585.34	Agua
12	5319036.55; 6561585.34	Agua sobre rastrojo de trigo
13	5317437.63; 6554540.20	Soja con charcos de agua
14	5317330.98; 6553883.63	Agua sobre rollos de alfalfa
15	5315191.94; 6542732.67	Maíz inundado parcialmente
16	5315371.45; 6543599.85	Agua
17	5322050.10; 6547885.33	Agua sobre Soja
18	5343643.18; 6543718.54	Agua
19	5327812.93; 6546959.95	Soja con charcos de agua

FUENTE: INTA Rafaela (2017) [14].

Continuando, se pueden observar las tres situaciones relevadas durante el muestreo en campo. En la primera (Figura 30) se aprecian dos lotes completamente inundados por las intensas precipitaciones ocurridas durante el período analizado, los cuales corresponden a los puntos de muestreo 4 y 16, respectivamente de la Tabla 3.



FUENTE: Carlos Caracci y D.Faure (2017) [15].

FIGURA 30: Lotes completamente inundados, puntos 4 (izq.) y 16 (der.).

En el caso de la Figura 31, la misma muestra lotes con cultivos de maíz inundados hasta una altura próxima a la mitad de su tamaño. A la izquierda de esta figura se aprecia la imagen tomada en el punto de muestreo 2 el día 3 de enero, con el cultivo recientemente inundado; a la derecha se aprecia la fotografía del lote correspondiente al punto 15 tomada el día 11 de enero, cuando ya se observaba la mortandad de las plantas de maíz a causa del anegamiento.



FUENTE: Carlos Caracci y D.Faure (2017) [15].

FIGURA 31: Lotes con maíz inundados, puntos 2 (izq.) y 15 (der.).

Es importante resaltar que este catálogo de fotografías tomadas durante la inundación es sumamente importante para el desarrollo de los algoritmos dado que rara vez se realiza un monitoreo detallado de las áreas inundadas durante el evento climático. Generalmente se efectúa varios días después de finalizado el mismo, cuando el clima ha mejorado y ha terminado la alerta. A continuación, en la Figura 32 se observan dos lotes con charcos de agua entre los surcos de soja y en la Figura 33 otros dos lotes cubiertos con sorgo y soja, respectivamente.



FUENTE: Carlos Caracci y D.Faure (2017) [15].

FIGURA 32: Lote con charcos de agua entre los surcos de soja, punto 13.



FUENTE: Carlos Caracci y D.Faure (2017) [15].

FIGURA 33: Lotes con charcos de agua en sorgo (punto 8 izq.) y en soja (punto 19 der.)

4.1.2 Datos Auxiliares

Se obtuvieron mapas de aptitud y uso del suelo del área de interés (INTA), límite de la cuenca del Arroyo Cululú y sus sub-cuencas (Secretaría de Recursos Hídricos - Provincia de Santa Fe), límite político del Departamento Castellanos y de sus Distritos (SCIT), modelo digital del terreno (USGS), datos de las precipitaciones acontecidas en el período comprendido entre el 14/10/2016 y el 17/02/2017 (Secretaría de Recursos Hídricos - Provincia de Santa Fe). Distintos informes desarrollados por el personal del INTA Rafaela durante el evento climático extremo que sucedió entre el 22/12/2016 y el 13/01/2017.

4.1.3 Imágenes Ópticas

Corresponden al satélite Sentinel 2A (S2A), sensor Multi Spectral Instrument (MSI), con nivel 1 de procesamiento (L1C), en el cual las imágenes vienen con valores de reflectancia en el tope de la atmósfera (TOA) y georreferenciadas. El sensor MSI toma imágenes con bandas multispectrales que presentan diferente resolución espacial (10, 20 y 60 metros). Para equiparar la resolución espacial de estas imágenes con las del SAR, se decidió utilizar las bandas de 20 m, la cuales son: las 5, 6 y 7 (corresponden a distintas porciones en el borde rojo del espectro visible), la 8A (infrarrojo cercano - NIR) y las bandas 11 y 12 (infrarrojo de onda corta - SWIR), mostrado en la Tabla 4. En cuanto a la fecha de adquisición, se estableció utilizar las más cercanas al período en donde ocurrieron las máximas precipitaciones (22/12/2016 al 13/01/2017), por lo tanto, la imagen pre-evento seleccionada fue la del 11/12/2016 y la del evento la del 10/01/2017.

TABLA 4: Día de adquisición y características de las imágenes ópticas - Sentinel 2A.

Id.	Fecha	Sensor	Nivel Procesamiento	Bandas (20 m)	Pasada
1	18/11/2016	MSI	L1C	5, 6, 7, 8a, 11 y 12	Descendente
2	11/12/2016	MSI	L1C	5, 6, 7, 8a, 11 y 12	Descendente
3	10/01/2017	MSI	L1C	5, 6, 7, 8a, 11 y 12	Descendente
4	27/01/2017	MSI	L1C	5, 6, 7, 8a, 11 y 12	Descendente

Otras imágenes ópticas: Se descargaron dos imágenes del satélite Landsat 8 sensor Operational Land Imager (OLI), ver Tabla 5, una previa al evento extremo (04/11/2016) y la otra cercana a la finalización del mismo (23/01/2017). Sin embargo, se decidió no utilizarlas dado que ambas estaban distantes del período en donde ocurrieron las máximas precipitaciones en comparación con las del Sentinel 2A.

TABLA 5: Día de adquisición y características de las imágenes ópticas Landsat 8.

Id.	Fecha	Sensor	Nivel Procesamiento	N° de Bandas	Pasada
5	04/11/2016	OLI	1	9	Descendente
6	23/01/2017	OLI	1	9	Descendente

Por último, se descargó una imagen del Satélite Sentinel 3A (S3A), sensor Ocean and Land Colour Instrument (OLCI), nivel 1 de procesamiento, con fecha 28/01/2017 (Tabla 6). Esta imagen no fue considerada dado su baja resolución espacial (300 metros).

TABLA 6: Día de adquisición y características de las imágenes ópticas - Sentinel 3A.

Id.	Fecha	Sensor	Nivel Procesamiento	N° de Bandas	Pasada
7	28/01/2017	OLCI	1	21	Descendente

4.1.4 Imágenes SAR

En este proyecto las imágenes SAR provienen del satélite Sentinel 1B que presenta las siguientes características: Banda C (5,6 cm), doble polarización (VV/VH) y el modo de adquisición denominado banda ancha interferométrica (IW) en el cual se adquieren las imágenes con un ancho de escena de 250 km y una resolución espacial de 5x20 metros, mostrada en la Figura 34. Las mismas fueron descargadas gratuitamente del catálogo Copernicus (<https://scihub.copernicus.eu/dhus/#/home>) de la Agencia Espacial Europea (ESA). Se tienen dos tipos de productos, el de nivel más básico llamado formato complejo de un solo look (Single Look Complex - SLC) y el rango terreno observado (Ground Range Detected - GRD). De las SLC se obtuvieron dos imágenes, una previa al fenómeno climático (21/12/2016) y la otra durante el mismo (14/01/2017). Con respecto a las GRD se adquirieron 14 imágenes, de las cuales 9 se tomaron antes de la inundación, 2 durante la misma y 3 luego del evento climático, ver Tabla 7.

TABLA 7: Día de adquisición y características de las imágenes SAR - Sentinel 1B.

Id.	Fecha	Modo	Tipo de Producto	Rango Ángulo Incidencia	Polarización	Pasada
1	10/09/2016	IW	GRD	38°- 46°	VV/VH	Descendente
2	28/09/2016	IW	GRD	38°- 46°	VV/VH	Descendente
3	10/10/2016	IW	GRD	38°- 46°	VV/VH	Descendente
4	22/10/2016	IW	GRD	38°- 46°	VV/VH	Descendente
5	03/11/2016	IW	GRD	38°- 46°	VV/VH	Descendente
6	15/11/2016	IW	GRD	38°- 46°	VV/VH	Descendente
7	27/11/2016	IW	GRD	38°- 46°	VV/VH	Descendente
8	09/12/2016	IW	GRD	38°- 46°	VV/VH	Descendente
9	21/12/2016	IW	GRD	38°- 46°	VV/VH	Descendente
10	02/01/2017	IW	GRD	38°- 46°	VV/VH	Descendente
11	14/01/2017	IW	GRD	38°- 46°	VV/VH	Descendente
12	26/01/2017	IW	GRD	38°- 46°	VV/VH	Descendente
13	07/02/2017	IW	GRD	38°- 46°	VV/VH	Descendente
14	19/02/2017	IW	GRD	38°- 46°	VV/VH	Descendente
15	21/12/2016	IW	SLC	38°- 46°	VV/VH	Descendente
16	14/01/2017	IW	SLC	38°- 46°	VV/VH	Descendente

Se indica que para poder realizar una adecuada comparación entre imágenes radar de distintas fechas, es muy importante trabajar con imágenes que tengan un ángulo de incidencia similar o muy cercano. Así mismo deben tener el mismo modo de pasada, ascendente o descendente, dado que no se puede mezclar imágenes con diferente modo.




FIGURA 34: Imagen SAR del satélite Sentinel 1B en modo IW.

4.2 MÉTODO

A continuación, se explica el método seguido y las principales características de los algoritmos de clasificación aplicados a las imágenes SAR para la obtención de la fracción inundada. Se puede observar el mismo en la Figura 35, en forma de diagrama de bloques. A través de este se pretende determinar la superficie inundada en el área de estudio, aplicando diversos algoritmos (Umbral Manual, Detección de Cambios, PolSAR e InSAR) sobre las imágenes SAR, validando los resultados a partir del muestreo *in situ* y las imágenes ópticas.

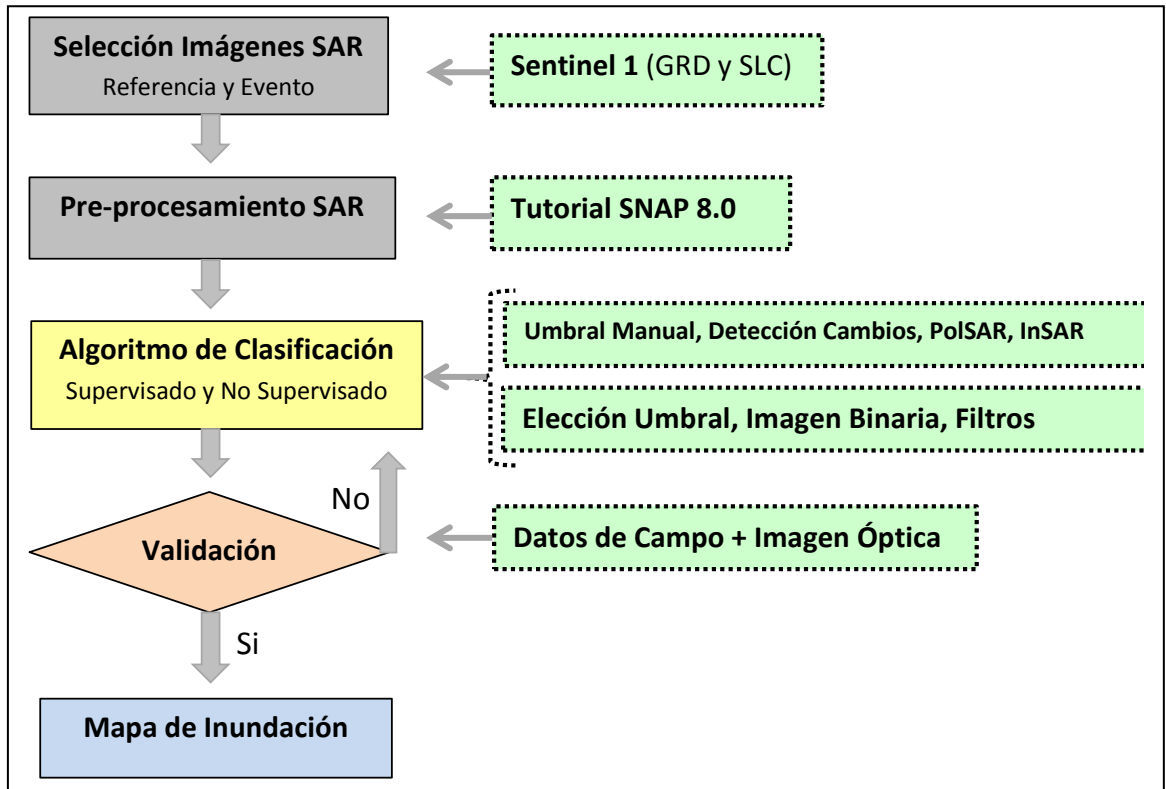


FIGURA 35: Método para la determinación del área inundada (izquierda), a la derecha (color verde) se observa la descripción de lo utilizado en cada etapa.

4.2.1 PRE-PROCESAMIENTO

Imagen Óptica

Las imágenes Sentinel 2A fueron pre-procesadas a través del recorte del área de estudio (subset) y la realización de realces y composiciones en color, para luego aplicar los índices de diferencias normalizadas de vegetación (NDVI) y de agua (NDWI). Además, para el caso de la imagen previa al evento climático extremo (11/12/2016) fue necesario realizar un mosaico del área de estudio dado que se trataba de dos imágenes de la misma órbita descendente (R110) adquiridas una a continuación de la otra.

Muestreo *in situ*

Los datos de campo obtenidos de los relevamientos efectuados sobre el área de interés los días 3, 11 y 12 de enero de 2017, fueron depurados para identificar sobre las imágenes SAR la presencia de lotes con cultivos inundados, tales como: maíz, girasol, soja, sorgo, alfalfa, etc. También permitió conocer la ubicación de lotes con suelo desnudo (rastros) anegados. Estos datos de campo fueron marcados

sobre las imágenes analizadas y empleados para la validación de los diferentes procesos aplicados a las imágenes SAR.

Imagen SAR

Las imágenes Sentinel 1B fueron pre-procesadas en el programa SNAP 8.0 según el procedimiento establecido para las imágenes SLC y GRD (H. Del Valle (2017) [75]. Este consiste en una secuencia de pasos que se comentan a continuación:

- Restablecer la órbita precisa a la imagen (precise orbit file);
- Remover el borde de la imagen (remove border noise);
- Eliminar el ruido térmico que pudiese estar presente en la imagen (thermal noise removal);
- Efectuar la calibración radiométrica de la imagen transformándola de ND (número digital) al valor físico de sigma cero (σ_0) (calibrate);
- Aplicar un multi-looking en orden a reducir el ruido de la escena y obtener un valor medio correcto de σ_0 (multilook);
- Ejecutar el filtrado del moteado (speckle) de la imagen, aplicando un filtro adaptativo Gamma Map (Speckle Filtering);
- Realizar la corrección geométrica al terreno (Range-Doppler Terrain Correction), en la cual se define el Modelo Digital del Terreno a utilizar (SRTM 1Sec), el método de remuestreo (interpolación bilinear), el tamaño del pixel (20,0 m x 20,0 m) y la proyección cartográfica (WGS 84 en coordenadas geográficas latitud y longitud);
- Por último, se efectúa la co-registración de las imágenes para dejarlas coincidentes entre sí (Coregistration - Stack).

A continuación, la Figura 36 muestra la herramienta (Graph Builder) que posee el software mencionado para generar una rutina que permite aplicar en secuencia todas las etapas del pre-procesamiento de las imágenes SAR en formato GRD. En el caso de las SLC se agrega una etapa más (Deburst) que es intermedia entre las de Calibration y Multilook, la misma permite juntar las franjas (burst) en que se subdivide la escena, dado que el SLC es un nivel más básico.

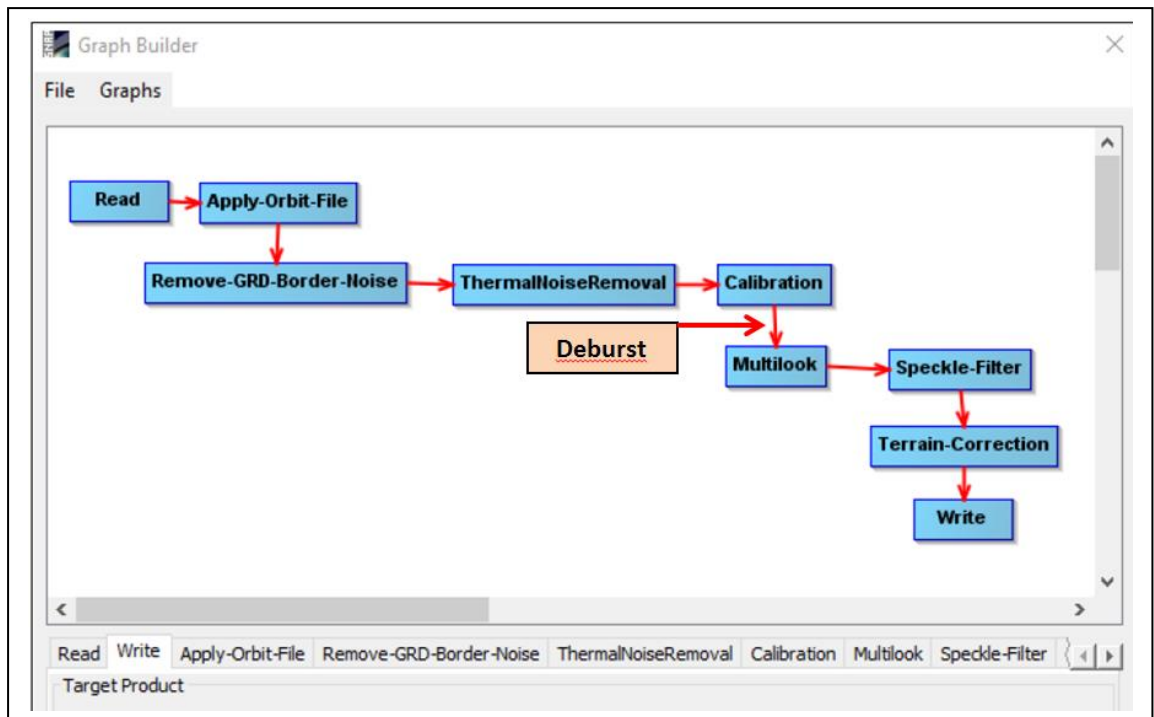


FIGURA 36: Procedimiento aplicado a las imágenes SAR Sentinel 1B (GRD y SLC).

4.2.2 PROCESAMIENTO

Imagen Óptica

A la imagen óptica del 11/12/2016, previa al evento climático, se le aplicó en primer término una composición color RGB-118a5 en la cual se le asigna el color rojo a la banda 11 del infrarrojo de onda corta, el verde a la banda 8a del infrarrojo cercano y el azul a la banda 5 de la porción del visible correspondiente al rojo (las imágenes son muestreadas y discutidas en el capítulo 6). A continuación, se realizó el índice de vegetación (NDVI):

$$NDVI = \frac{BandaInfrarrojoCercano(8a) - BandaRojo(5)}{BandaInfrarrojoCercano(8a) + BandaRojo(5)}$$

A partir del NDVI se obtuvo la cobertura del suelo:

- Suelo desnudo con rastrojo principalmente de trigo;
- Cultivos, tales como, maíz, girasol, soja, alfalfa, etc.;
- Cañadas.

Luego se efectuó una composición color similar a la anterior (RGB-118a5) sobre la imagen del 10/01/2017 adquirida durante el período de inundación. Posteriormente, se calculó para la misma el índice de agua (NDWI):

$$NDWI = \frac{BandaRojo(5) - BandaInfrarrojodeOndaCorta(11)}{BandaRojo(5) + BandaInfrarrojodeOndaCorta(11)}$$

De esta manera con el NDWI se determinó el área inundada libre de vegetación, es decir, aquellos sectores que fueron cubiertos por el agua y cuya cobertura correspondía a suelo desnudo (con rastrojo), cultivos (alfalfa, soja, etc.), pastizales y cañadas.

A continuación, se aplicó la técnica de interpretación visual de imágenes, sobre la composición color RGB-118a5 y el índice NDWI generados ambos con la imagen óptica del 10/01/2017, empleándose los principales criterios de interpretación (color, textura y forma), para digitalizar el contorno de dos cubetas o bajos presentes en el área de estudio, los cuales se encontraban completamente inundados durante el período considerado. Los dos polígonos generados fueron considerados como la verdad del terreno y, por lo tanto, áreas de comparación de las superficies anegadas determinadas por las diferentes técnicas de procesamiento de las imágenes SAR.

Imagen SAR

A las imágenes Sentinel 1B pre-procesadas se les aplicaron distintos métodos de clasificación supervisados y no supervisados con objeto de extraer las áreas inundadas, tales como: Umbral Manual, Detección de Cambios, Polarimetría (PolSAR) e Interferometría (InSAR). Se debe aclarar que en el procesamiento de las imágenes SAR se empleó el siguiente procedimiento:

- 1) Ejecución del algoritmo de clasificación considerado (umbral manual, detección de cambios, PolSAR e InSAR);
- 2) Determinación del umbral sobre la imagen procesada por un dado método de clasificación;
- 3) Aplicación del umbral sobre la imagen procesada a partir del uso de operadores lógicos y aritmética de imágenes, con objeto de obtener una imagen binaria con las clases agua y no agua;
- 4) Empleo de filtros sobre la imagen binaria. En primer término se aplica un filtro de mediana (3x3) para quitar píxeles aislados presentes en cada imagen binaria obtenida por cada técnica; y en segundo lugar, se utiliza un filtro morfológico de cierre (closing 3x3) con el objeto de rellenar los espacios vacíos que quedan en las áreas determinadas.

4.2.3 MÉTODOS DE CLASIFICACIÓN APLICADOS

A continuación, se comentará en detalle la aplicación del procedimiento de cuatro etapas indicado arriba. La primera etapa consiste en la aplicación de un algoritmo de clasificación, en primer término se utilizó uno supervisado denominado Umbral Manual. Se aclara que el mismo procedimiento se aplicó para los demás algoritmos de clasificación empleados.

4.2.3.1 Umbral Manual

- 1) Para la aplicación de este algoritmo de clasificación supervisada se analizaron visualmente las dos polarizaciones (VV-VH) y el cociente entre ambas (VV/VH) de la imagen SAR adquirida el 14/01/2017. Se escogió la misma en detrimento de la del 02/01/2017 por estar esta última afectada por las precipitaciones sucedidas entre el 2 y el 3 de dicho mes. Además, se efectuó una composición color RGB_ VV-VH-VV/HV.
- 2) Luego, continuando con el procedimiento se determinó el umbral por debajo del cual se podía considerar como clase 1 (agua) y por encima del mismo clase 0 (no agua). Este umbral se obtuvo para cada polarización (VV y VH) y también para la imagen del cociente (VV/VH). El mismo se determinó analizando los histogramas de cada imagen.
- 3) A continuación, se aplicó un operador lógico para obtener la imagen binaria de agua y no agua. Estos fueron del tipo:

$$\text{Si } \sigma_0 \text{ VV} \leq \text{umbral} \text{ entonces } 1 \text{ sino } 0$$

Es decir, si el valor de un dado píxel de la imagen (VV en este caso) era menor o igual que el umbral determinado, se lo consideraba como clase 1 (agua), de lo contrario era de la clase 0 (no agua). Por lo tanto, se obtuvieron tres imágenes binarias derivadas de las dos polarizaciones (VV y VH) y del cociente (VV/VH). A las mismas se les aplicó una operación aritmética de suma para obtener la superficie total anegada en el área de interés:

$$\text{Superficie Inundada} = \text{binaria (VV)} + \text{binaria (VH)} + \text{binaria (VV / VH)}$$

- 4) Finalmente, se aplicaron los filtros de mediana (3x3) y morfológico de cierre (closing 3x3) sobre la imagen binaria final derivada de la suma de las otras tres (VV, VH y VV/VH).

4.2.3.2 Detección de Cambios

Indica todas aquellas técnicas utilizadas para comparar las intensidades de la retrodispersión (σ_0) antes y durante la inundación, con el objeto de detectar cambios en los píxeles causados por la misma. Para tal se emplean dos imágenes, una como referencia “seca”, adquirida previa a la inundación, y la otra tomada durante la misma. El principio detrás de las técnicas de detección de cambios es sencillo y es efectivo para superar la sobredetección de áreas inundadas debido a superficies lisas similares al agua, tales como: rutas pavimentadas, pistas de aeropuerto, suelo desnudo, etc. La técnica de detección de cambios se puede extender también al uso de múltiples imágenes de referencia secas. En el marco de esta técnica de detección de cambios se aplicaron Índices de Inundación y Cocientes de bandas que serán explicados a continuación.

I Índices de inundación

Basado en el principio de la Detección de Cambios, se aplicó para ambas polarizaciones (VV y VH) el Índice de Inundación de Diferencia Normalizada (NDFI) y el Índice de Vegetación Inundada de Diferencia Normalizada (NDFVI), empleando en primer término como referencia “seca” la imagen del 28/09/2016 y como “inundada” la del 14/01/2017. En segundo lugar, la referencia estuvo dada por una serie de ocho (8) imágenes tomadas previas al evento climático y como imagen “inundada” la misma que en el primer caso. A continuación, se muestran ambos índices extraídos de F. Cian *et al.* (2018) [48]:

$$NDFI = \frac{\text{media } \sigma (\text{referencia}) - \text{mín } \sigma (\text{referencia e inundada})}{\text{media } \sigma (\text{referencia}) + \text{mín } \sigma (\text{referencia e inundada})}$$

$$NDFVI = \frac{\text{máx } \sigma (\text{referencia e inundada}) - \text{media } \sigma (\text{referencia})}{\text{máx } \sigma (\text{referencia e inundada}) + \text{media } \sigma (\text{referencia})}$$

Primer caso:

Referencia: imagen σ_0 (28/09/2016)

Inundada: imagen σ_0 (14/01/2017)

En este primer caso, se realizó la co-registración (stack) de las 2 imágenes (referencia e inundada), luego se calcularon los estadísticos mínimo y máximo entre ambas imágenes. En el caso de la media estadística, al ser una sola la imagen de referencia, esta última actúa como tal.

A continuación, se aplicó el procedimiento comentado arriba, esto es, se obtuvieron ambos índices (NDFI e NDFVI) en cada polarización (VV y VH), luego se determinaron los umbrales, posteriormente se aplicaron los mismos a través de los operadores lógicos para derivar las imágenes binarias que representan en un caso la inundación en aguas abiertas (NDFI) y, en el otro, la vegetación inundada no cubierta por el agua (NDFVI). Finalmente se emplearon los filtros de mediana y morfológico.

Segundo caso:

Referencia: Serie de 8 imágenes σ_0 (del 28/09/2016 al 21/12/2016) (Tabla 4).

Inundada: imagen σ_0 (14/01/2017)

En este segundo caso, para obtener los índices (NDFI e NDFVI), también fue necesario realizar la co-registración de las 9 imágenes (8 de la serie previa a la inundación y una inundada), a continuación se obtuvieron los estadísticos (media, mínimo y máximo), en el caso de la media se calculó a partir de las 8 imágenes que constituían la serie de referencia y para la obtención del mínimo y el máximo se emplearon las 9 imágenes (referencias + inundada).

Luego se continuó con la aplicación de los cuatro pasos del procedimiento comentado precedentemente con el propósito de derivar las imágenes binarias que representen la inundación y la vegetación inundada.

II Cociente de bandas

Continuando con la Detección de Cambios, se aplicó el cociente de bandas que permite resaltar las diferencias entre la imagen de referencia y la del evento climático, en ambas polarizaciones:

$$\text{Cociente } \sigma_0 VV = \frac{\text{imagen } \sigma_{vv} (\text{referencia})}{\text{imagen } \sigma_{vv} (\text{inundada})}$$

$$\text{Cociente } \sigma_0 VH = \frac{\text{imagen } \sigma_{vh} (\text{referencia})}{\text{imagen } \sigma_{vh} (\text{inundada})}$$

Primer caso:

Referencia: imagen σ_0 (28/09/2016)

Inundada: imagen σ_0 (14/01/2017)

En este primer caso, se emplearon las imágenes en formato GRD y se efectuaron los cocientes para ambas polarizaciones: Cociente $\sigma_{0VV} = \sigma_{0VV}$ (Referencia) / σ_{0VV} (Inundada), lo mismo para el cociente VH.

Segundo caso:

Referencia: Imagen σ_0 (21/12/2016)

Inundada: imagen σ_0 (14/01/2017)

En este segundo caso, se emplearon las imágenes en formato SLC y se realizaron los mismos cocientes que en el primero. Esto es: Cociente $\sigma_{0VV} = \sigma_{0VV}$ (Referencia) / σ_{0VV} (Inundada), similarmente para el cociente VH.

En ambos casos (GRD y SLC), luego de obtener los cocientes en las dos polarizaciones (VV y VH), se continuó con la ejecución de las tres etapas restantes del procedimiento utilizado para la determinación de las imágenes binarias de inundación, esto es, selección del umbral, obtención de la imagen binaria (agua - no agua) y la aplicación de los filtros para generalización de la imagen.

4.2.3.3 PolSAR

Para aplicar la técnica de polarimetría se requiere de una imagen SAR en el nivel más básico denominado SLC (complejo de un solo look). Se contaba con dos imágenes en dicho formato, una previa (21/12/2016) y una durante el evento crítico (14/01/2017), eligiéndose esta última para la aplicación de dicha técnica.

En primer término se procede a la generación de la matriz polarimétrica de Covarianza (C2), siendo esta la única opción dado que se cuenta con una imagen SLC de dos polarizaciones (VV y VH). En caso de tener una imagen SAR completamente polarizada (HH, VV, HV y VH), es posible aplicar la matriz polarimétrica de Coherencia (T3).

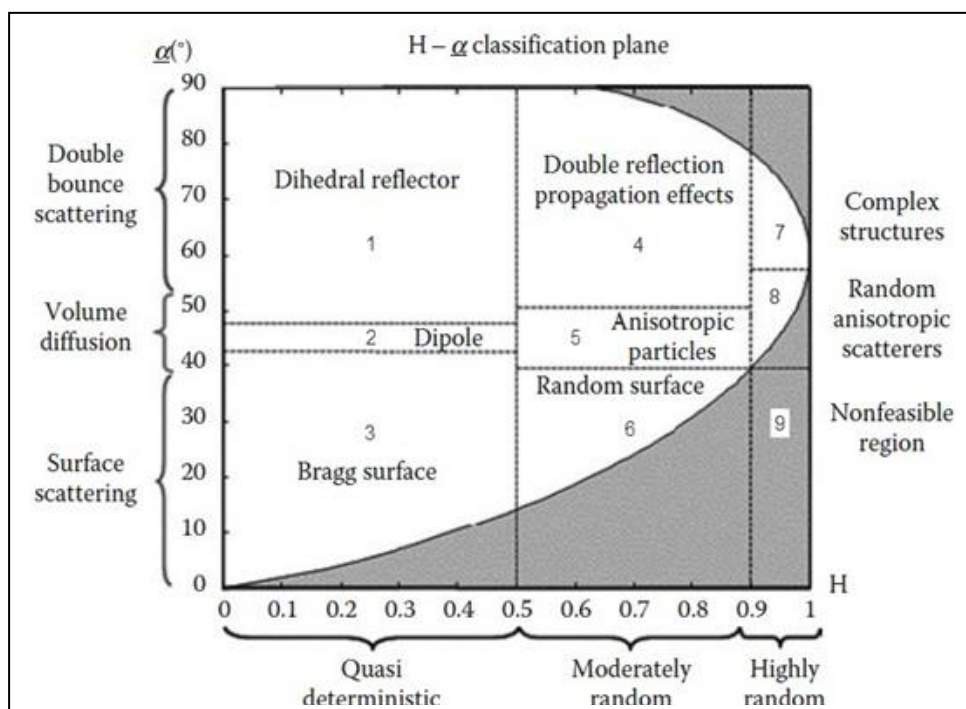
El paso siguiente es aplicar un filtro para reducir el efecto del moteado (speckle), para tal, se eligió el denominado filtro refinado de Lee (Sentinel-1 Toolbox, 2020). A continuación, se aplicaron dos técnicas polarimétricas diferentes, la primera consistió en la obtención de los parámetros polarimétricos (entropía, alfa y anisotropía) y la segunda en la ejecución de una clasificación polarimétrica no supervisada, ambos procesos son comentados a continuación.

I Parámetros Polarimétricos (H, α y A)

Se realizó la descomposición polarimétrica y, por tratarse de una imagen SAR con doble polarización, el programa utilizado para procesarla solo dispone de una opción denominada descomposición H-Alfa Dual Pol. Esta descomposición polarimétrica genera los tres parámetros: Entropía (H), Alfa (α) y Anisotropía (A). Luego de la obtención de tales parámetros polarimétricos (H, α y A) se procede a completar las tres etapas faltantes del procedimiento indicado para derivar las imágenes binarias de inundación.

II Clasificación Polarimétrica No Supervisada

Se aplicaron dos clasificaciones polarimétricas no supervisadas denominadas: Cloude-Pottier y H Alpha Wishart, respectivamente. La primera de ellas se basa en el uso del plano Entropía (H) / Alfa (α). La entropía, por definición, es una medida de la aleatoriedad o desorden de los datos retrodispersados, mientras que el ángulo alfa se puede utilizar para identificar los mecanismos de dispersión dominantes en la escena. Por lo tanto, el plano H / α se divide en nueve zonas correspondientes a clases que representan los mecanismos de dispersión y su grado de desorden. Para cada píxel de la imagen se calculan su entropía y ángulo alfa, y en función de ellos se clasifica el píxel en una de las nueve zonas, ver Figura 37.



FUENTE: SNAP 8.0 (2020).

FIGURA 37: Plano H / Alfa

Ambas clasificaciones (Cloude-Pottier y H Alpha Wishart), separan los datos en nueve grupos utilizando las zonas definidas en el plano H / α de la Figura 41. Sin embargo, la clasificación H Alpha Wishart continua recalculando los centros de los nueve grupos en un número de iteraciones indicado por el usuario, luego de lo cual clasificará los píxeles en función de sus distancias a cada uno de dichos centros de grupo (SNAP 8.0, 2020).

También, en estos dos casos luego de efectuadas las clasificaciones no supervisadas, se procedió a completar los tres pasos restantes del procedimiento para la determinación de las imágenes binarias de inundación.

4.2.3.4 InSAR

Para aplicar la técnica de Interferometría SAR se requiere de dos imágenes en el formato SLC (complejo de un solo look). Como ya fue indicado se contaba con dos de ellas, una previa (21/12/2016) y una durante la inundación (14/01/2017), las cuales fueron empleadas para su ejecución. En este caso, se aplicó la técnica solo para obtener la imagen de coherencia en donde poder analizar cambios en la cobertura del suelo relacionados a la inundación. Para esto se efectuaron los siguientes pasos (Sentinel-1 Toolbox, 2020):

- Coregistración de ambas imágenes (stack);
- Ejecución del interferograma;
- Cálculo de la coherencia interferométrica;
- Realización del Multilooking;
- Aplicación del filtro denominado Goldstein Phase Filtering;
- Realización de la corrección geométrica al terreno (Range-Doppler Terrain Correction).

Una vez obtenida la imagen corregida de coherencia, se aplican los pasos faltantes del procedimiento para la determinación de las superficies anegadas (selección de umbral, binarización de la imagen y ejecución de filtros).

5. DESCRIPCIÓN DE HIPÓTESIS

Como fue comentado, en la actualidad la ejecución de mapas de inundación en superficies abiertas, esto es, cuando el agua cubre completamente los suelos y los cultivos, se ha logrado efectuar con una precisión aceptable que permite incorporarlo como un procedimiento operativo en las instituciones del estado provincial encargadas de los recursos naturales (agua, suelo, bosques, etc.) o de la producción (agropecuaria). Sin embargo, todavía se presentan dificultades en la detección de superficies inundadas debajo de la vegetación empleando datos SAR en diferentes bandas y/o polarizaciones. Por lo tanto, se plantea la siguiente hipótesis:

“Es posible detectar lotes rurales inundados en los cuales el agua queda oculta por las hojas de un determinado tipo de cultivo, a partir de considerar el incremento de la señal SAR retrodispersada ocasionado por el mecanismo de dispersión de doble rebote agua-tallo”.

A partir de la hipótesis planteada se pretende adicionar a los mapas de inundación actuales, que consideran solo las superficies abiertas inundadas, las áreas con determinados tipos de cultivos inundados parcialmente, es decir, aquellas en donde el agua no cubre en su totalidad a las plantas.

6. RESULTADOS

6.1 PROCESAMIENTO

6.1.1 Imagen Óptica

A la imagen óptica Sentinel 2 del 11/12/2016, previa al evento climático, se le aplicó en primer término una composición color RGB-118a5 en la cual se le asigna el color rojo a la banda 11 del infrarrojo de onda corta, el verde a la banda 8a del infrarrojo cercano y el azul a la banda 5 de la porción del visible correspondiente al rojo. A continuación, se realizó el índice de vegetación (NDVI), ver Figura 38:

$$NDVI = \frac{\text{Banda Infrarrojo Cercano (8a)} - \text{Banda Rojo (5)}}{\text{Banda Infrarrojo Cercano (8a)} + \text{Banda Rojo (5)}}$$




FIGURA 38: Composición color RGB-118a5 (izq.) e índice de vegetación NDVI (der.) de la imagen óptica Sentinel 2 adquirida el 11/12/2016.

A partir del NDVI se obtuvo la cobertura vegetal del área de estudio, representada de color verde en la Figura 42 (derecha) aplicando un umbral de 0,4. La misma incluye los cultivos (maíz, soja, girasol, alfalfa, etc.) y los pastizales presentes en las cañadas. Además en la misma figura se aprecian en color gris los suelos desnudos con presencia de rastrojo principalmente de trigo.

Luego se efectuó una composición color similar a la anterior (RGB-118a5) sobre la imagen Sentinel 2 del 10/01/2017 adquirida durante el período de inundación. Posteriormente, se calculó el índice de agua (NDWI):

$$NDWI = \frac{\text{Banda Rojo (5)} - \text{Banda Infrarrojo de Onda Corta (11)}}{\text{Banda Rojo (5)} + \text{Banda Infrarrojo de Onda Corta (11)}}$$

De esta manera se le aplicó al índice de agua NDWI un umbral de 0,1 para determinar las superficies abiertas inundadas, es decir, aquellas áreas en las cuales el agua cubre por completo los lotes, independientemente del tipo de cobertura que estos tengan (suelo desnudo, cultivos o pastizales), ver Figura 39.




FIGURA 39: RGB-118a5 (izq.) e índice de agua NDWI (der.) de la imagen Sentinel 2 del 10/01/2017.

A continuación, a partir de una interpretación visual de la composición color (RGB-118a5) de la imagen del 10/01/2017 y con apoyo en la imagen del NDWI, se procedió a digitalizar los contornos de dos cubetas o bajos que se encontraban inundados dentro el área de interés (Figura 40). Se generaron entonces, dos polígonos a los cuales se los empleó como la verdad del terreno para comparar los resultados obtenidos por las diferentes técnicas aplicadas a las imágenes SAR en la delimitación de las áreas anegadas.

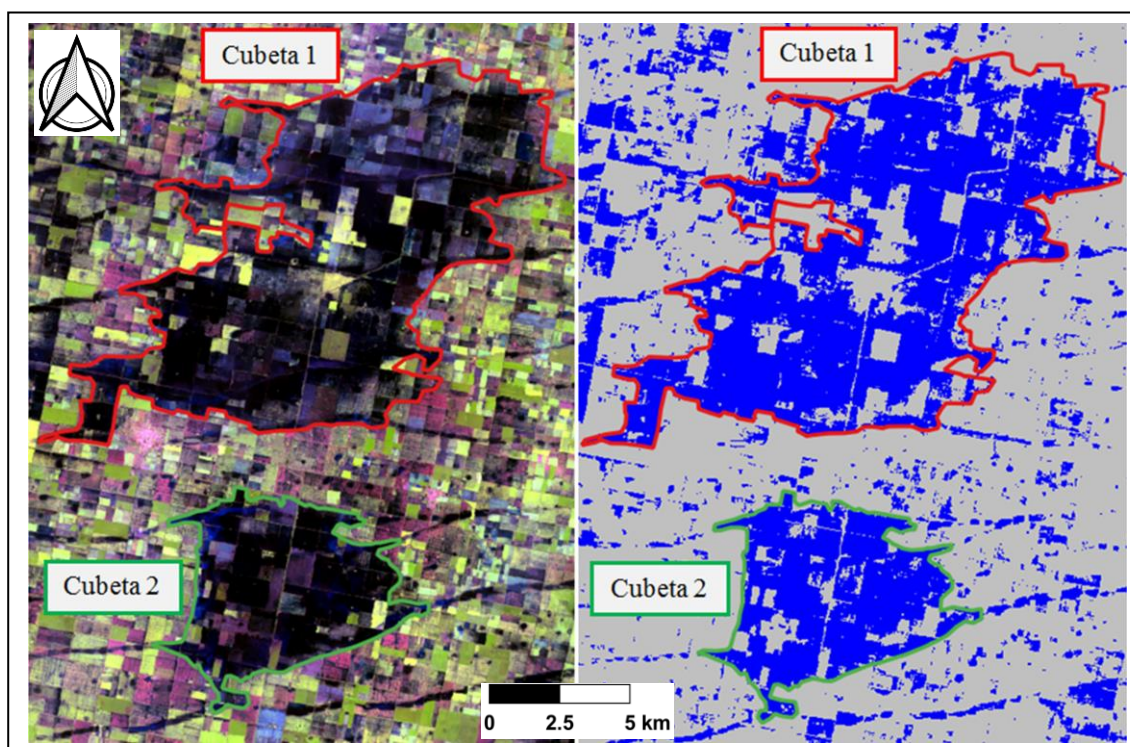


FIGURA 40: Cubetas o bajos digitalizados por interpretación visual de la imagen RGB-118a5 (izquierda) y del índice de agua NDWI (derecha) de la imagen Sentinel 2 del 10/01/2017.

6.1.2 Imagen SAR

Según señalado en el método, las imágenes Sentinel 1B fueron procesadas aplicando el siguiente procedimiento:

- 1) Ejecución de la técnica considerada: Umbral Manual, Detección de Cambios, PoSAR e InSAR;
- 2) Determinación del umbral sobre la imagen procesada con una dada técnica;
- 3) Aplicación del umbral sobre la imagen procesada a partir del uso de operadores lógicos y aritmética de imágenes, con objeto de obtener una imagen binaria con las clases agua y no agua, las cuales indican si está o no inundado;
- 4) Empleo de filtros sobre la imagen binaria. En primer término se aplica un filtro de mediana (3x3) para quitar píxeles aislados presentes en la imagen binaria (agua - no agua) derivada de cada técnica aplicada; y en segundo lugar, se utiliza un filtro morfológico de cierre (3x3) con el objeto de rellenar los espacios vacíos que quedan en las áreas determinadas como agua.

A continuación, se muestran los resultados obtenidos a partir de la aplicación del procedimiento de cuatro pasos mencionado arriba sobre las imágenes Sentinel 1B (formatos GRD y SLC) para determinar la superficie inundada en la cubeta 1. Es necesario comentar, que también se aplicó el mismo sobre la cubeta 2, sin embargo, con objeto de observar mejor los detalles alcanzados solo se muestran sobre la primera.

6.2 MÉTODOS DE CLASIFICACIÓN APLICADOS

6.2.1 Umbral Manual

Para la aplicación de este algoritmo de clasificación supervisado se analizó la imagen Sigma0 (σ_0 , formato GRD) con polarizaciones VV y VH adquirida el 14/01/2017. Se escogió la misma en detrimento de la del 02/01/2017 por estar esta última afectada por las intensas precipitaciones sucedidas ese mismo día en el área de estudio. Además, se efectuó el cociente entre las bandas (VV/VH) y una composición color RGB_VV-VH-VV/HV.

Para el análisis visual de ambas polarizaciones y el cociente entre ellas, realizado sobre la cubeta 1, se les asignó a las imágenes una escala de grises teniendo el valor mínimo y el máximo los tonos negro y blanco, respectivamente. De dicha observación resulta que la imagen σ_0 VV resalta en color negro el agua de la inundación “libre”, es decir, no obstruida por los cultivos en la cual se produce el mecanismo de dispersión especular de la señal al interceptarla. También, realza en color blanco los cultivos inundados parcialmente, es decir, aquellos en los cuales el agua cubre solo la parte media-inferior de las plantas dando lugar al mecanismo de interacción agua-tallo denominado doble rebote, mostrado en la Figura 41.

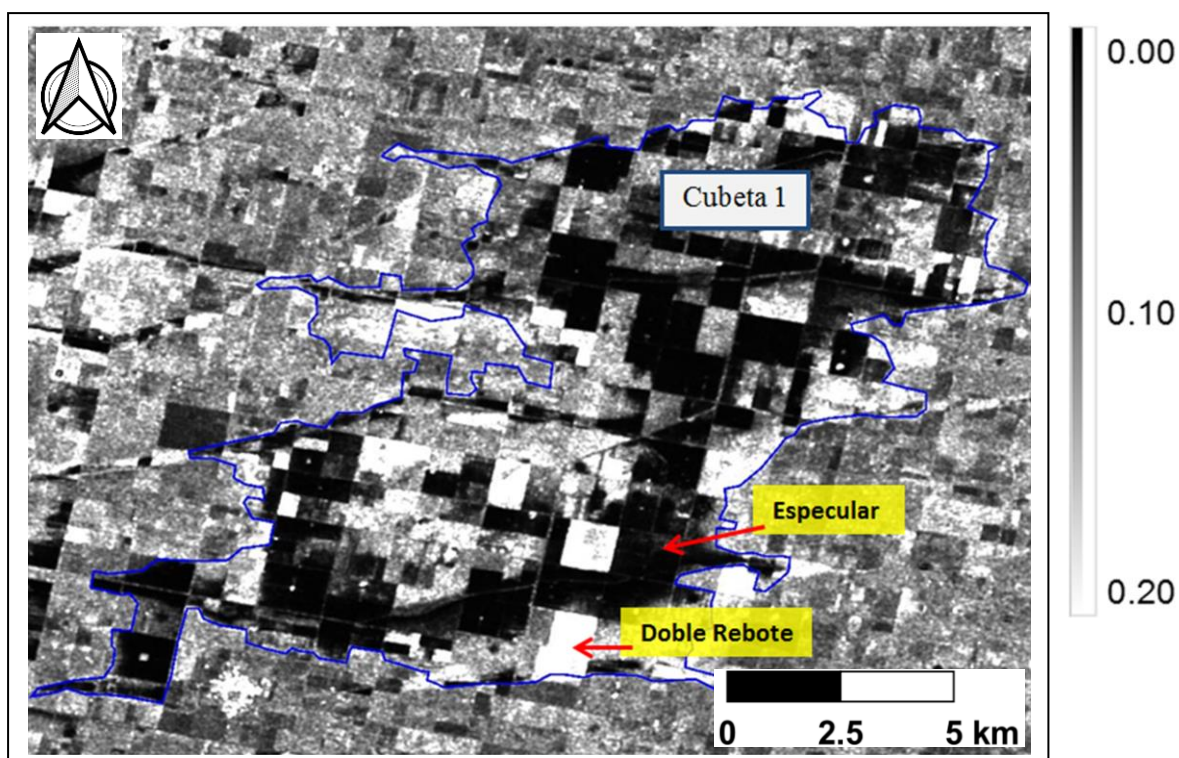


FIGURA 41: Imagen Sigma0 VV se observan las áreas inundadas en la cubeta 1, en color negro cuando se produce dispersión especcular y en blanco para doble rebote.

Por su parte, la imagen σ_0 VH resalta mejor, en color negro, la superficie inundada debido al mecanismo de dispersión especcular. Sin embargo, no destaca la dispersión de doble rebote que sucede cuando el agua no sobrepasa la altura de los cultivos (Figura 42), dado que este mecanismo de dispersión no depolariza la señal.




FIGURA 42: Imagen Sigma0 VH se aprecia en color negro la dispersión especcular.

En cuanto al cociente $\text{Sigma0 VV} / \text{Sigma0 VH}$ éste destaca en color blanco, tanto, el mecanismo de dispersión de doble rebote agua-tallo (con valores ≥ 15), en donde la imagen Sigma0 VV presenta valores más altos que la Sigma0 VH , como, áreas con dispersión especular (con valores en el rango ≥ 5 y < 15) en las cuales la imagen Sigma0 VV disminuye sus valores en relación a la Sigma0 VH . Además, se aprecian en color negro otros sectores de agua “libre” con dispersión especular (valores < 5), en donde los valores de ambas imágenes (VV y VH) se tornan similares (Figura 43).

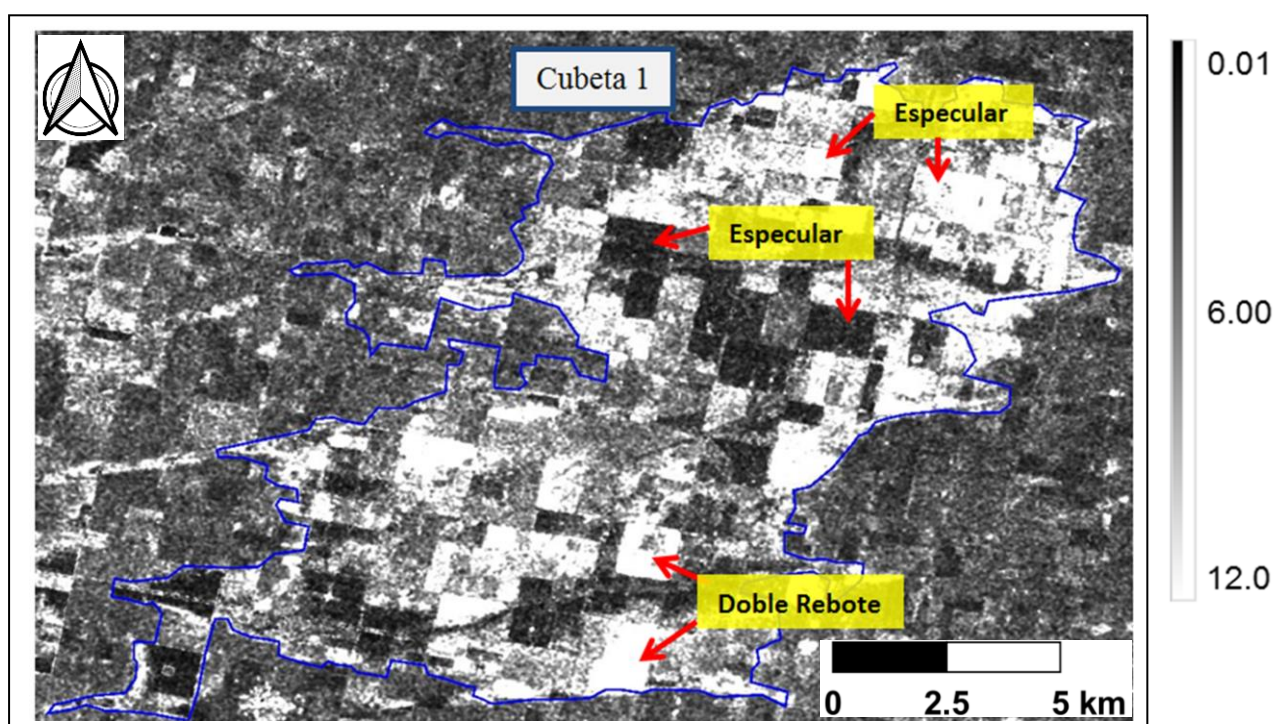


FIGURA 43: Imagen del cociente $\text{Sigma0 VV} / \text{Sigma0 VH}$, se observan en color blanco áreas con dispersión de doble rebote y especular; y en negro las que tienen solo especular.

A continuación, la Figura 44 muestra la composición color RGB_VV-VH-VV/VH la cual permite apreciar claramente lo comentado anteriormente para cada imagen por separado. Por lo tanto, se observan en color negro las áreas anegadas de agua “libre” (dispersión especular), en magenta los cultivos anegados (doble rebote) resaltados por la imagen Sigma0 VV y el cociente $\text{Sigma0 VV} / \text{Sigma0 VH}$; y en color azul otras áreas con dispersión especular resaltadas por el cociente $\text{Sigma0 VV} / \text{Sigma0 VH}$.




FIGURA 44: La composición color RGB_VV-VH-VV/VH muestra en color negro y azul la dispersión especular y en magenta la de doble rebote.

Continuando con el método de Umbral Manual, la segunda etapa consiste en determinar los umbrales para aplicar a las imágenes consideradas (σ_0 VV, σ_0 VH y cociente σ_0 VV/ σ_0 VH), para obtener los mismos, se tuvo en cuenta cual era el mecanismo de dispersión que se observaba mejor en cada una de estas imágenes. Entonces, en el caso de la Sigma0 VV el umbral fijado permitió separar los lotes con dispersión de doble rebote, en el caso de Sigma VH el umbral seleccionado fue para separar las superficies con dispersión especular y finalmente para el cociente Sigma0 VV / Sigma0 VH, el umbral establecido permitió también diferenciar las áreas con dispersión de doble rebote.

A continuación, se muestra el umbral determinado sobre la imagen σ_0 VV para separar las superficies con dispersión de doble rebote, es decir, aquellas en las cuales el agua inunda la porción media-inferior de las plantas. Para esto se analizó, por un lado, los valores del histograma (Figura 45) y, por otro, los valores digitales individuales de los píxeles localizados en tales lotes que se apreciaban en color blanco en dicha imagen.




FIGURA 45: Umbral aplicado a la Imagen Sigma0 VV para diferenciar las áreas inundadas donde se produce dispersión de doble rebote.

En el caso de la imagen σ_0 VH el umbral fijado fue con objeto de diferenciar las superficies de agua “libre” en donde se produce dispersión especular. Al igual que en el caso anterior, se analizaron tanto el histograma de la imagen (Figura 46), como, los valores digitales de los píxeles que aparecían de color negro.




FIGURA 46: Umbral aplicado a σ_0 VH para diferenciar áreas inundadas con disper. especular.

Por último, para el cociente σ_0VV/σ_0VH se determinó un umbral que permitiera separar los sectores inundados con dispersión de doble rebote (agua-tallo) de los que presentan dispersión especular. Por lo tanto, se analizó la imagen del cociente y su histograma (Figura 47) y se determinó que los valores de los píxeles eran ≥ 15 en donde se producía el mecanismo de interacción de doble rebote.

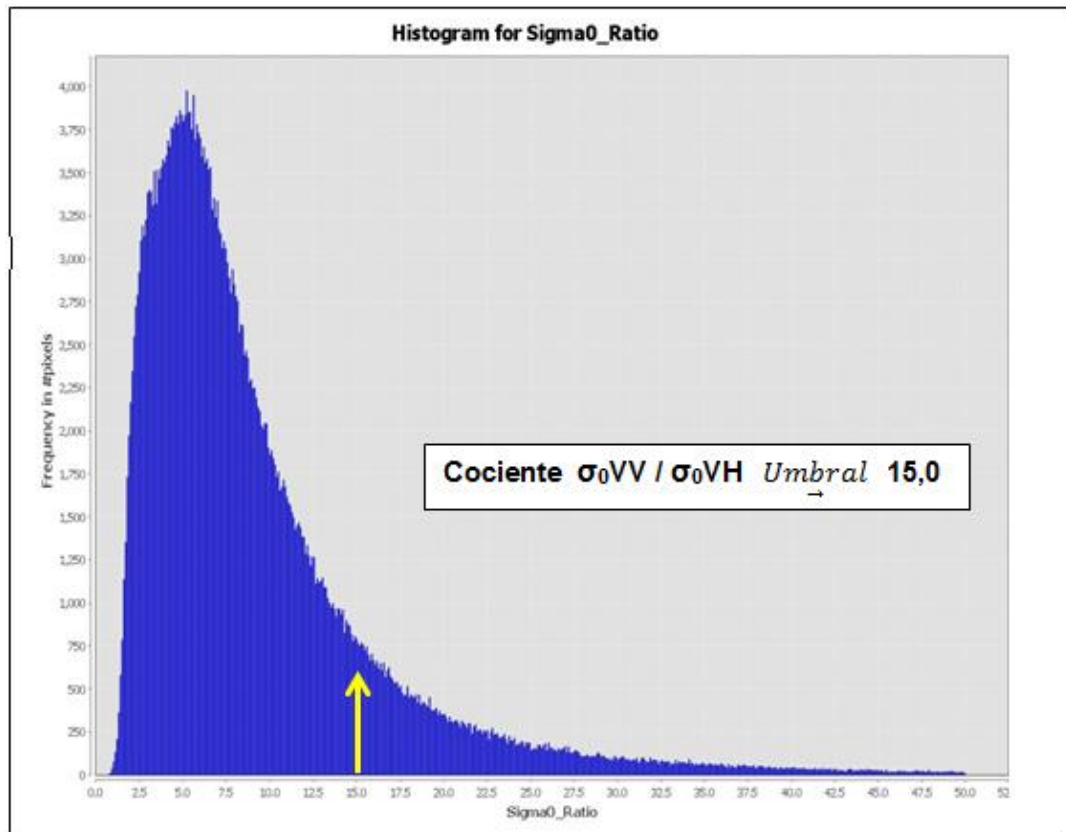


FIGURA 47: Umbral aplicado al cociente VV/VH para diferenciar áreas inundadas con dispersión de doble rebote.

Luego, se continuó con el tercer paso del procedimiento consistente en la aplicación de los umbrales seleccionados para cada imagen considerada, con objeto de generar las imágenes binarias (agua - no agua).

Por lo tanto, en el caso de la imagen $\sigma_0 VV$ se estableció la siguiente condición:

- Si $\sigma_0 VV \geq 0,25$ implica se produce una interacción de doble rebote entre la vegetación y el agua resaltando los lotes de cultivos inundados en donde el agua cubre solo la porción media-inferior de las plantas (Figura 48).




FIGURA 48: Imagen binaria resultante del umbral aplicado a Sigma0 VV, en azul las áreas anegadas en donde se produce dispersión de doble rebote.

Para la imagen σ_0 VH, la condición instituida fue:

- Si σ_0 VH $\leq 0,003$ implica existe dispersión especular sobre la superficie del agua, por lo tanto, se trata de lotes inundados en donde el agua cubre completamente el suelo desnudo y los cultivos (Figura 49).




FIGURA 49: Imagen binaria derivada del umbral aplicado a Sigma0 VH, en azul las áreas anegadas con dispersión especular.

Para el cociente $\sigma_0 VV / \sigma_0 VH$ se determinó:

- Si $\sigma_0 VV / \sigma_0 VH \geq 15,0$ implica se ha producido una dispersión de doble rebote agua-tallo, ver Figura 50.




FIGURA 50: Imagen binaria obtenida del umbral aplicado al cociente $\sigma_0 VV / \sigma_0 VH$ en azul se aprecian las áreas anegadas que son resaltadas por la dispersión de doble rebote agua-tallo.

Para obtener la superficie total inundada se realizó la suma de las tres imágenes binarias obtenidas al aplicar los umbrales mencionados:

$$\text{Superficie Total Inundada} = \text{Binaria } \sigma_0 VV \text{ (DR)} + \text{Binaria } \sigma_0 VH \text{ (Esp.)} + \text{Binaria } \sigma_0 VV / \sigma_0 VH \text{ (DR)}$$

Dónde:

DR: Doble Rebote

Esp.: Especular

Finalmente, y según el procedimiento establecido, el último paso consiste en la aplicación, a la imagen final resultante de la suma, de los filtros de mediana (3x3) y morfológico de cierre (3x3) para la eliminación de píxeles aislados y espacios vacíos, respectivamente (Figura 51).

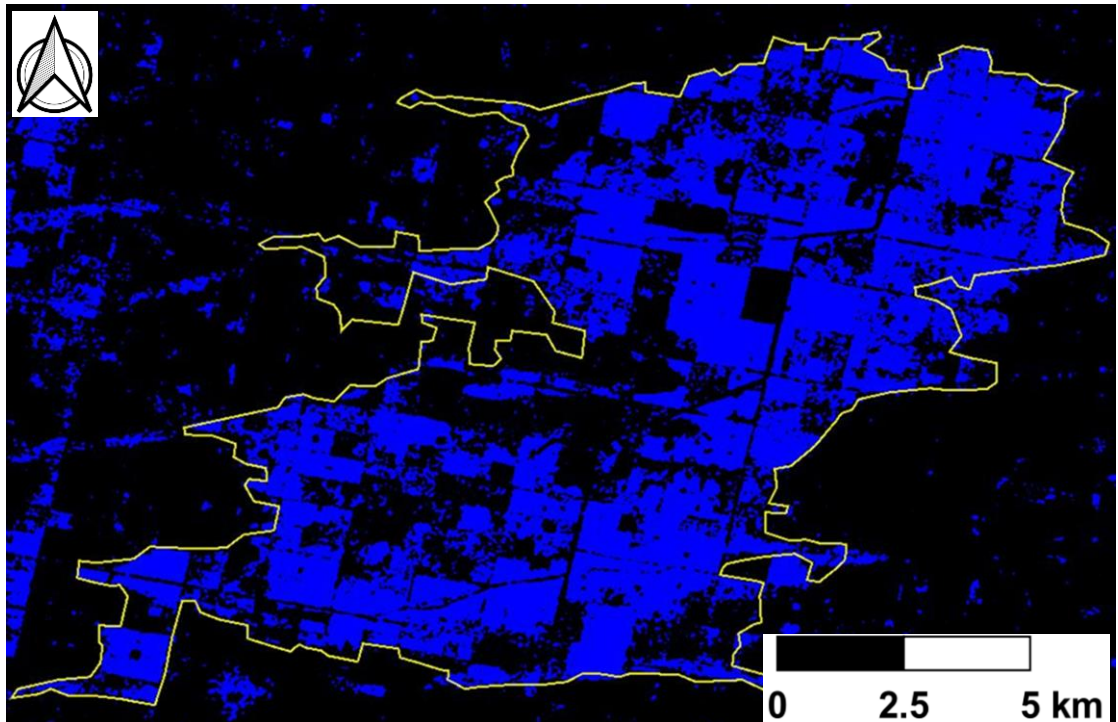


FIGURA 51: Superficie total inundada (azul) el día 14/01/2017 según el algoritmo de clasificación supervisado denominado Umbral Manual.

6.2.2 Detección de Cambios

6.2.2.1 Índices de Inundación

Según comentado, se aplicaron índices para la Detección de Cambios, entre ellos: el Índice de Inundación de Diferencia Normalizada (NDFI) [53] y el Índice de Vegetación Inundada de Diferencia Normalizada (NDFVI) [53]. Ambos se calcularon para las dos polarizaciones de la imagen (VV y VH). Además, se emplearon en dos casos diferentes, en el primero se utilizó una (1) imagen de referencia “seca” y en el segundo se empleó una serie de ocho (8) imágenes “secas” adquiridas antes de la inundación. En ambos casos la imagen “inundada” fue la misma.

Primer caso:

Referencia: imagen σ_0 (28/09/2016)

Inundada: imagen σ_0 (14/01/2017)

Entonces, en primer término se calculan ambos índices:

$$NDFI = \frac{\text{media } \sigma (\text{referencia}) - \text{mín } \sigma (\text{referencia e inundada})}{\text{media } \sigma (\text{referencia}) + \text{mín } \sigma (\text{referencia e inundada})}$$

$$NDFVI = \frac{\text{máx } \sigma (\text{referencia e inundada}) - \text{media } \sigma (\text{referencia})}{\text{máx } \sigma (\text{referencia e inundada}) + \text{media } \sigma (\text{referencia})}$$

La Figura 52 muestra el índice $NDFI_{vH}$ en donde se observa en color blanco la dispersión especular característica de las superficies de agua “abierta”. A diferencia en la Figura 53, correspondiente al índice $NDFVI_{vV}$, se aprecia en color blanco la dispersión de doble rebote (agua-tallo) propia de los cultivos inundados en los cuales el agua no alcanza a cubrirlos.

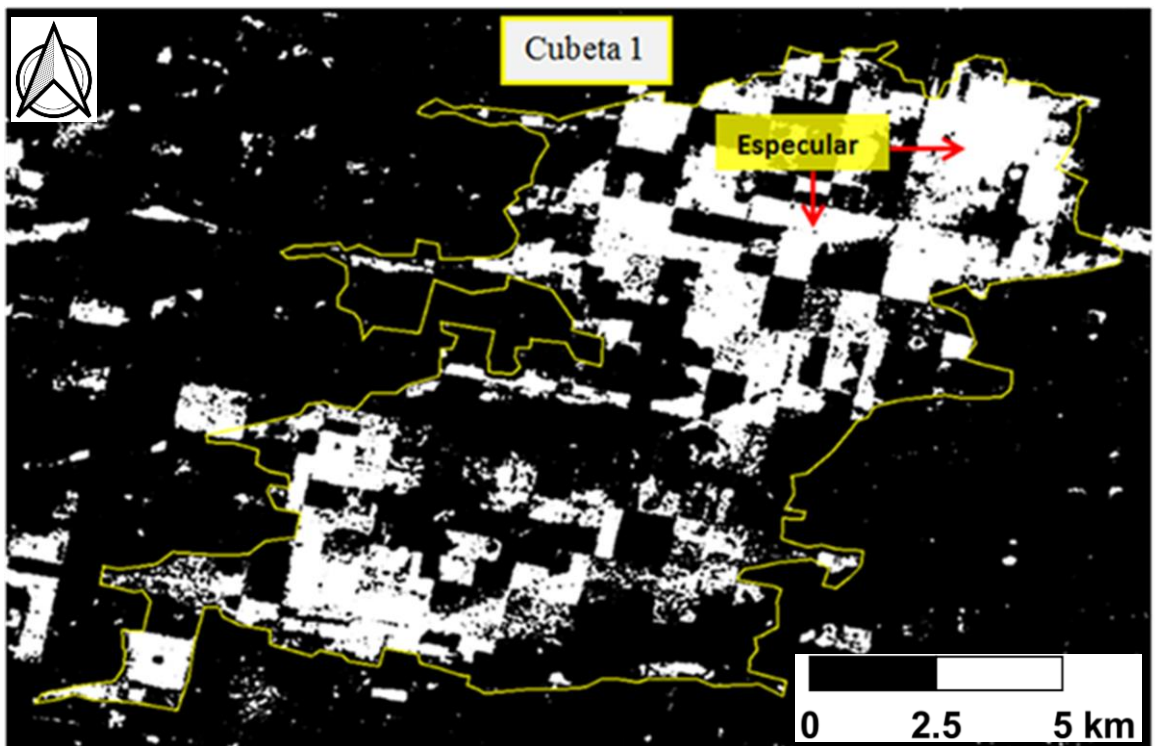


FIGURA 52: Imagen del índice $NDFI_{vH}$, se observa en color blanco la dispersión especular.




FIGURA 53: Imagen del índice NDFVI_{VV}, se ve en color blanco la dispersión doble rebote.

A seguir, se muestran los umbrales fijados para los dos índices (NDFI e NDFVI) en ambas polarizaciones (VV y VH):

NDFI_{VH} Umbral 0,25

NDFI_{VV} Umbral 0,3

NDFVI_{VH} Umbral 0,8

NDFVI_{VV} Umbral 0,8

A continuación, se aplicaron tales umbrales a los índices en ambas polarizaciones, obteniéndose en primer término las imágenes binarias del NDFI_{VV} y NDFI_{VH}, en las cuales se identificaron los sectores cubiertos con agua “libre” de vegetación y se observó que ambos se complementaron, por lo tanto, se realizó la suma de las áreas marcadas por cada uno de los mismos para obtener de esta manera las superficies abiertas inundadas (Figura 54).

$$\text{NDFI}_{VV+VH} = \text{NDFI}_{VV} + \text{NDFI}_{VH}$$




FIGURA 54: Imagen resultante de la suma de las imágenes binarias de los índices $NDFI_{VV+VH}$, en azul las áreas anegadas con dispersión especular.

En cuanto a los índices $NDFVI_{VV}$ y $NDFVI_{VH}$, el primero resaltó la dispersión doble rebote en aquellos lotes con cultivos inundados hasta una cierta altura de las plantas. El segundo, hizo lo mismo pero en exceso. Por lo tanto, se decidió emplear solo el primero de ellos, ver Figura 55.




FIGURA 55: Imagen binaria del umbral aplicado al índice $NDFVI_{VV}$, en azul las áreas anegadas con dispersión de doble rebote.

Finalmente se realizó la suma del índice de inundación $NDFI_{VV+VH}$ con el índice de vegetación inundada $NDFVI_{VV}$ (Figura 56):

$$\text{Superficie Total Inundada} = NDFI_{VV+VH} + NDFVI_{VV}$$




FIGURA 56: Superficie total inundada (azul) determinada por el algoritmo supervisado de detección de cambios utilizando índices de inundación $NDFI$ e $NDFVI$ (primer caso).

Segundo caso:

Referencia: Serie de 8 imágenes σ_0 (28/09/2016 - 21/12/2016)

Inundada: imagen σ_0 (14/01/2017)

En este segundo caso, la referencia seca estuvo dada por una serie de 8 imágenes adquiridas antes del inicio de las precipitaciones extremas que ocasionaron la inundación (Tabla 7). Contar con un conjunto de imágenes constituye una ventaja cuando comparado con el uso de una sola imagen de referencia, la cual puede estar afectada por las condiciones particulares presentes el día de su adquisición. Por el contrario, aplicar un promedio permite obtener una referencia más confiable. A continuación, se calcularon los índices de inundación:

$$NDFI = \frac{\text{media } \sigma (\text{serie referencia}) - \text{mín } \sigma (\text{serie referencia e inundada})}{\text{media } \sigma (\text{serie referencia}) + \text{mín } \sigma (\text{serie referencia e inundada})}$$

$$NDFVI = \frac{\text{máx } \sigma (\text{serie referencia e inundada}) - \text{media } \sigma (\text{serie referencia})}{\text{máx } \sigma (\text{serie referencia e inundada}) + \text{media } \sigma (\text{serie referencia})}$$

La Figura 57 muestra el índice NDFI_{vv} en donde se observa en color blanco la dispersión especular del agua. Por el contrario, la Figura 58 correspondiente al índice NDFVI_{vv}, muestra en color blanco la dispersión de doble rebote propia de los cultivos inundados en los cuales el agua cubre parcialmente las plantas hasta una dada altura.




FIGURA 57: Imagen del índice NDFI_{vv}, se observa en color blanco la dispersión especular.




FIGURA 58: Imagen del índice NDFVI_{vv}, se ve en color blanco la dispersión doble rebote.

Continuando, se presentan los umbrales determinados para ambos índices en las dos polarizaciones:

NDFI_{VH} Umbral 0,7

NDFI_{VV} Umbral 0,7

NDFVI_{VH} Umbral 0,6

NDFVI_{VV} Umbral 0,6

Luego de aplicar los umbrales a las imágenes de los índices, se observa que el índice de inundación NDFI_{VV}, aplicado a las imágenes con polarización semejante vertical - vertical (VV), resalta mejor el agua “libre” que el NDFI_{VH}, con polarización cruzada vertical - horizontal (VH), ver Figura 59.




FIGURA 59: Imagen del umbral aplicado al NDFI_{VV} en azul áreas anegadas con especular.

En cuanto a los índices de vegetación inundada, solo el NDFVI_{VV}, derivado de las imágenes con polarización VV, resaltó bien los lotes con cultivos inundados hasta una cierta altura, mostrado en la Figura 60.




FIGURA 60: Imagen del umbral aplicado al índice NDFVI_{vv} en azul las áreas inundadas con dispersión doble rebote producida entre el agua y los tallos de las plantas.

Por último, se decidió efectuar la suma entre los índices de inundación NDFI_{vv} y de vegetación inundada NDFVI_{vv} (Figura 61):

$$\text{Superficie Total Inundada} = \text{NDFI}_{vv} + \text{NDFVI}_{vv}$$




FIGURA 61: Superficie total inundada (azul) el día 14/01/2017 determinada por el algoritmo supervisado de detección de cambios utilizando índices NDFI e NDFVI (segundo caso).

6.2.2.2 Cociente de bandas

Para la aplicación de este método de detección de cambios se emplearon dos cocientes diferenciados. En el primero se utilizaron las imágenes σ_0 en formato GRD y en el segundo las de formato SLC, estando en ambos casos los valores de σ_0 en potencia (lineal). Además, para ambos formatos el cociente se realizó dividiendo la imagen de referencia “seca” por la inundada, en ambas polarizaciones.

Primer caso:

Referencia: imagen σ_0 (28/09/2016)

Inundada: imagen σ_0 (14/01/2017)

En este primer caso, se emplearon las imágenes en formato GRD y se efectuaron los cocientes para ambas polarizaciones: Cociente VV = σ_{0VV} (Referencia) / σ_{0VV} (Inundada), lo mismo para el Cociente VH, mostrado en la Figura 62.




FIGURA 62: Imágenes de los Cocientes VH (arriba) y VV (abajo), en ambas se observan en blanco la dispersión especular del agua y en negro la de doble rebote agua-tallo.

Del análisis de la Figura anterior, es posible apreciar que ambos cocientes identificaron bien aquellos lotes completamente cubiertos por el agua, donde se producía una interacción especular. Sin embargo, en los lotes inundados en los cuales los cultivos cubrían el agua, provocando una dispersión de doble rebote, estos se observaron con mayor contraste en el cociente VV eligiéndose este en detrimento del cociente VH. Luego, se establecieron los siguientes umbrales en los cocientes para resaltar ambos tipos de dispersión:

Cociente v_H *Umbral* \rightarrow **1,5** (Especular)

Cociente v_V *Umbral* \rightarrow **1,5** (Especular)

Cociente v_V *Umbral* \rightarrow **0,1** (Doble Rebote)

A continuación, se emplearon dichos umbrales para obtener las imágenes binarias (agua - no agua) de ambos mecanismos de interacción. Para el caso de las superficies abiertas inundadas, con dispersión especular, y dado que ambos cocientes (VH y VV) se complementaban, se efectuó la suma de las imágenes binarias de los mismos (Figura 63):

Superficie Inundada (dispersión especular) = Cociente VV + Cociente VH




FIGURA 63: Superficie inundada (azul) el día 14/01/2017 con dispersión especular obtenida de la suma de ambos Cocientes (VV + VH) de las imágenes en formato GRD.

Como fue comentado, para determinar las áreas inundadas en las cuales el agua resultaba tapada por las plantas de los cultivos, se empleó solo el cociente VV (Figura 64): **Superficie Inundada** (dispersión doble rebote) = Cociente VV




FIGURA 64: Superficie inundada (azul) con dispersión de doble rebote obtenida del Cociente VV de las imágenes en formato GRD.

Finalmente, para obtener la superficie total inundada se realizó la suma de las imágenes binarias que representaban ambos mecanismos de interacción (Figura 65):

$$\text{Sup. Total Inundada} = \text{Disp. Especular}_{\text{Coc.VV}} + \text{Coc.VH} + \text{Disp. Doble rebote}_{\text{Coc. VV}}$$




FIGURA 65: Superficie total inundada (azul) derivada de los Cocientes VH y VV formato GRD.

Segundo caso:

Referencia: Imagen σ_0 (21/12/2016)

Inundada: imagen σ_0 (14/01/2017)

En este segundo caso, se emplearon las imágenes en formato SLC y se realizaron los mismos cocientes que en el primero. Esto es: Cociente VV = σ_{0VV} (Referencia) / σ_{0VV} (Inundada), lo mismo para el Cociente VH. Luego, se efectuó una composición color entre los mismos RGB_CocienteVV-CocienteVH-CocienteVH observándose que ambos cocientes (VV y VH) resaltaron, en color blanco, el agua de la inundación sin cobertura vegetal (interacción especular), lo cual fue complementado con el Cociente VH a partir del cual se agregaron otros lotes inundados con dispersión especular, los que se aprecian en color cian (Figura 66).




FIGURA 66: Composición color RGB_CocienteVV - CocienteVH - CocienteVH, se observan en color blanco y en cian las áreas inundadas con dispersión especular.

A continuación, se instauraron los umbrales para ambos cocientes:

Cociente_{VH} *Umbral* **2,0**

Cociente_{VV} *Umbral* **2,0**

Continuando, se efectuó la suma de las imágenes binarias de ambos cocientes para determinar las superficies abiertas inundadas no obstruidas por los cultivos (dispersión especular), ver Figura 67.

Superficie Inundada (dispersión especular) = Cociente VV + Cociente VH




FIGURA 67: Superficie inundada (azul) el día 14/01/2017 con dispersión especular derivada de la suma de ambos Cocientes (VV + VH) de las imágenes en formato SLC.

Para determinar las áreas inundadas con dispersión doble rebote, en las cuales el agua estaba tapada por los cultivos, se empleó el cociente VV (Figura 68).

Superficie Inundada (dispersión doble rebote) = Cociente VV




FIGURA 68: Superficie inundada (azul) con dispersión doble rebote obtenida del Cociente VV.

Por último, para derivar el área total inundada se efectuó la suma de ambas imágenes binarias que indicaban los mecanismos de dispersión especular y doble rebote, respectivamente (Figura 69):

$$\text{Sup. Total Inundada} = \text{Disp. Especular}_{\text{Coc.VV}} + \text{Coc.VH} + \text{Disp. Doble rebote}_{\text{Coc. VV}}$$




FIGURA 69: Superficie total inundada (azul) derivada de los Cocientes VH y VV formato SLC.

6.2.3 PolSAR

Como fue comentado en el método, la aplicación de la técnica PolSAR cuenta de diferentes pasos, siendo el último de ellos la descomposición polarimétrica, en este trabajo se aplicó la denominada descomposición Entropía-Alfa obteniéndose tres parámetros polarimétricos: Entropía (H), Alfa (α) y Anisotropía (A), los cuales se relacionaron con los mecanismos de dispersión (especular y doble rebote) presentes en la escena. Finalmente, se realizó una clasificación polarimétrica no supervisada.

6.2.3.1 Parámetros Polarimétricos (H, α y A)

Se analizaron y compararon los tres parámetros polarimétricos obtenidos (Entropía-H, Alfa- α y Anisotropía-A). A continuación, se comentan los resultados obtenidos con cada parámetro y los umbrales aplicados a los mismos. En el caso de Alfa (α), se observó que resalta en color blanco las áreas inundadas de agua “libre” donde se produce interacción especular, dejando en color negro los lotes anegados con cultivos, no tapados por el agua, con dispersión de doble rebote (Figura 70).




FIGURA 70: Imagen del parámetro polarimétrico Alfa (α) en donde se observan en color blanco las áreas con dispersión especular y en negro con doble rebote.

Para el caso de la Entropía (H), presenta una imagen similar al parámetro anterior (Alfa- α) pero con menor contraste, con lo cual se resaltan menos los objetos de interés (Figura 71). Por lo tanto, se decidió no emplearla.




FIGURA 71: Imagen del parámetro Entropía (H) derivado de la imagen del 14/01/2017.

En cuanto a la Anisotropía (A), se apreció que se comporta de manera opuesta al parámetro Alfa- α , es decir, resalta en color blanco los lotes con cultivos inundados en donde el agua no alcanza a cubrirlos (interacción de doble rebote) y en color negro las áreas anegadas en donde el agua tapa por completo los lotes produciendo dispersión especular (Figura 72).




FIGURA 72: Imagen del parámetro polarimétrico Anisotropía (A) en donde se aprecian en color blanco las áreas con dispersión de doble rebote y en negro con especular.

Siguiendo el procedimiento, se fijaron los siguientes umbrales para destacar los sectores con dispersión especular y de doble rebote:

- Si $\alpha \geq 35$ implica se destacan los lotes inundados completamente cubiertos por el agua (dispersión especular);
- Si $\alpha \leq 12$ implica se resaltan los lotes anegados con cultivos, en los cuales el agua no cubre los mismos (dispersión doble rebote);
- Si $A \leq 0,35$ implica se destacan los lotes anegados completamente por el agua (interacción especular);
- Si $A \geq 0,85$ implica se resaltan los lotes anegados con cultivos en los cuales el agua los cubre parcialmente (interacción de doble rebote).

A continuación, se aplicaron los umbrales mencionados utilizando diferentes operadores lógicos para resaltar, por un lado, las superficies abiertas inundadas donde el agua cubre completamente el suelo (dispersión especular) y, por otro, las superficies donde el agua inunda parcialmente los cultivos sin llegar a cubrirlos (dispersión de doble rebote). Estos operadores fueron aplicados simultáneamente en ambas imágenes de los parámetros Alfa (α) y Anisotropía (A).

Para resaltar la dispersión especular se utilizó la rutina:

$$\text{Alfa} \geq 35 \text{ or Anisotropía} \leq 0,35$$

Es decir, cualquiera de las dos condiciones que se cumpla implica la presencia de agua “libre”, es decir, sin obstrucción por vegetación (Figura 73).




FIGURA 73: Superficie inundada (azul) derivada de la dispersión especular en el agua “libre”.

En el caso de la dispersión de doble rebote se aplicó la siguiente rutina:

$$\text{Alfa} \leq 12 \text{ or Anisotropía} \geq 0,85$$

Esto es, cualquiera de las dos condiciones que suceda indica la presencia de cultivos anegados parcialmente por el agua produciéndose entonces una interacción de doble rebote (Figura 74).




FIGURA 74: Superficie inundada (azul) determinada de la dispersión de doble rebote.

Por último, se realizó la suma de ambas imágenes (dispersión especular y doble rebote) obtenidas de la aplicación de las rutinas a los umbrales de las imágenes de los parámetros α y A, con objeto de obtener la superficie total inundada (Figura 75).

Sup. Total Inundada = Dispersión Especular (α -A) + Dispersión Doble Rebote (α -A)




FIGURA 75: Superficie total inundada (azul) obtenida de la clasificación supervisada de los parámetros polarimétricos Alfa (α) y Anisotropía (A).

6.2.3.2 Clasificación Polarimétrica No Supervisada

Se aplicó una clasificación polarimétrica no supervisada denominada H-Alpha Wishart. Se obtuvieron 9 clases según el plano de clasificación H- α (Figura 41) que corresponden a diferentes comportamientos de dispersión. De estas se identificaron dos que representaban los mecanismos de dispersión de interés (Figura 76):

- **Clase 3:** indica, según el plano de clasificación H- α , una dispersión de superficie con baja entropía o aleatoriedad. La misma marca (en color anaranjado) superficies abiertas inundadas en donde se produce dispersión especular.
- **Clase 7:** corresponde, según el plano de clasificación H- α , a una dispersión de doble rebote con alta entropía o aleatoriedad. Esta clase señala (en color azul) los lotes con cultivo anegados en donde el agua queda oculta por las hojas de los mismos produciéndose el mencionado mecanismo de interacción de doble rebote.

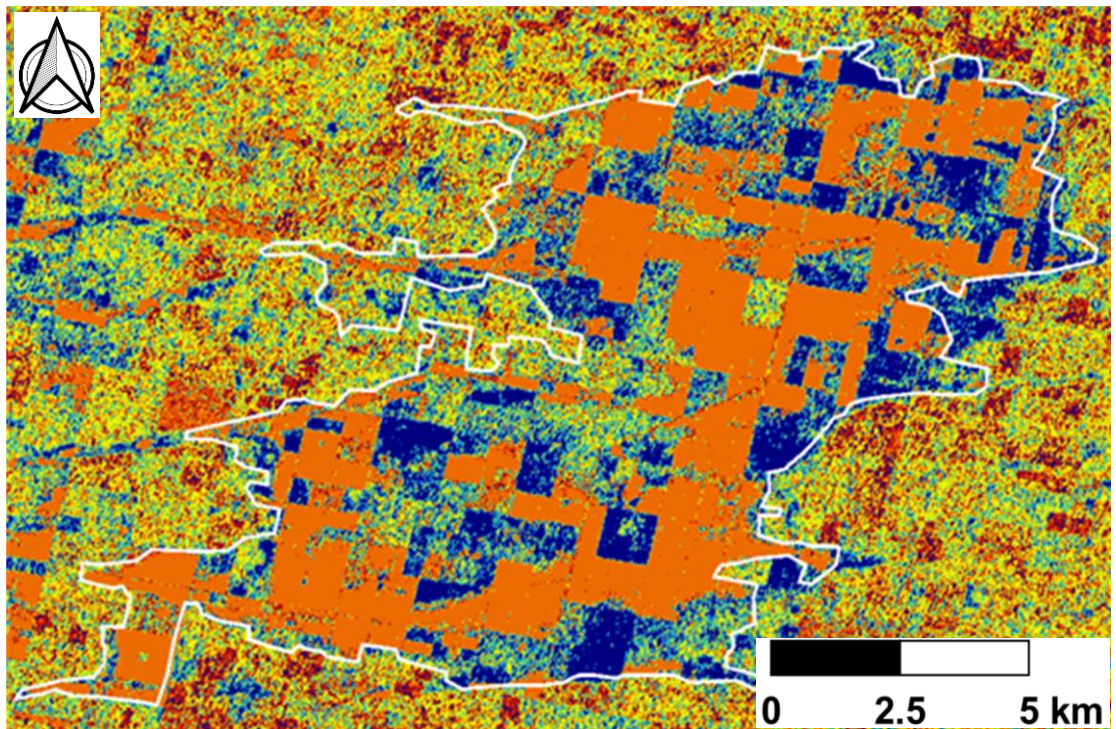


FIGURA 76: Clasificación polarimétrica H-Alpha Wishart indicando en color anaranjado la dispersión especular (clase 3) y en azul la de doble rebote (clase 7).

Luego se aplicaron dichos umbrales (3 y 7) para obtener imágenes binarias de superficies inundadas de agua “libre” y áreas anegadas con los cultivos ocultando el agua, respectivamente (Figuras 77 y 78).




FIGURA 77: Superficie inundada (azul) con interacción especular (clase 3).




FIGURA 78: Superficie inundada (azul) con dispersión de doble rebote (clase 7).

Finalmente, se realizó la suma de ambas imágenes (dispersión especular y de doble rebote) derivándose la superficie inundada en el área analizada (Figura 79).

Sup. Total Inundada = Disper. Especular (clase 3) + Disper. Doble Rebote (clase 7)




FIGURA 79: Superficie total inundada (azul) derivada de la clasificación H-Alpha Wishart.

6.2.4 InSAR

También la aplicación de esta técnica, al igual que la polarimétrica, consta de diferentes pasos, siendo uno de ellos la determinación de la coherencia, la cual se puede utilizar para conocer la ocurrencia de cambios en la cobertura del terreno entre la adquisición de ambas imágenes complejas (SLC). Como fue comentado previamente, una coherencia cercana a 1 indicará la ausencia de cambios en la cobertura del terreno y una próxima a 0 mostrará todo lo contrario.

Se obtuvo la imagen de Coherencia en ambas polarizaciones (VV y VH) observándose valores de la misma cercanos a 1 solo en las áreas urbanas, como era de esperar, dado que son las únicas que no cambiaron entre el período de tiempo transcurrido (24 días) entre la adquisición de ambas imágenes SLC (21/12/2016 y 14/01/2017).

Con respecto a la cobertura de los lotes rurales, tales como: cultivos de diversos tipos, pastizales, etc. los mismos presentan una muy baja coherencia, con un valor medio en torno a 0,27 (Figura 80), dado que la misma se ve muy afectada por los cambios en la posición de los cuerpos reflectantes durante el lapso de tiempo considerado, que se produce por el movimiento de las hojas de los cultivos o pastizales debido al viento.

También, la coherencia se ve perturbada por las mudanzas en las propiedades dieléctricas (humedad) de los objetos, la cual sin dudas se modificó entre una imagen y la siguiente. En la adquirida el día 21/12/2016 la vegetación se encontraba con menor humedad ($<$ cte. dieléctrica) debido a no haber recibido precipitaciones. Por el contrario, cuando se tomó la segunda imagen el 14/01/2017 ya se había producido el evento climático extremo ($>$ de 500 mm de lluvias) incrementando notablemente la humedad del ambiente ($>$ cte. dieléctrica).




FIGURA 80: Histograma de la imagen de Coherencia $_{VV}$ mostrando un valor medio de 0,27.

Por lo tanto, no fue posible la determinación de la superficie inundada en el área de estudio empleando la imagen de Coherencia, dado que la misma mostraba cambios (valores bajos) en toda la superficie ocurridos durante el lapso de tiempo considerado, con excepción de las áreas urbanas las cuales no fueron de interés en este trabajo (Figura 81).

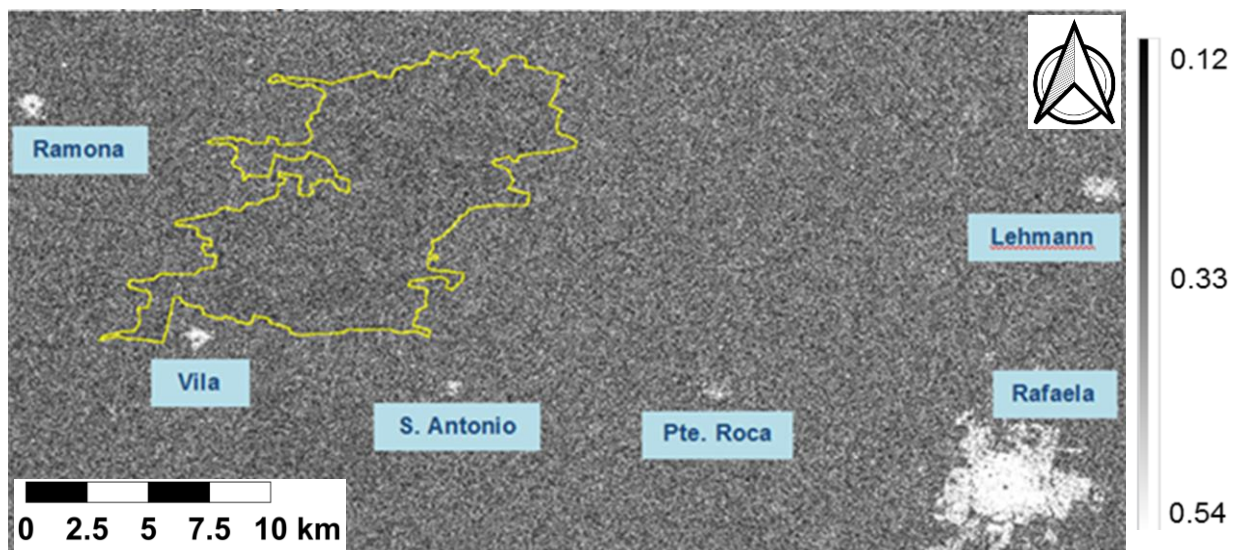


FIGURA 81: Imagen de Coherencia $_{VV}$ mostrando valores bajos (grises) en las áreas rurales y valores altos (blanco) en las áreas urbanas.

7. ANÁLISIS DE LOS RESULTADOS

7.1 COMPARACIÓN DE LOS MÉTODOS DE CLASIFICACIÓN

Para comparar las diferentes métodos de clasificación aplicados a las imágenes SAR, se emplearon dos polígonos correspondientes a las cubetas o bajos presentes en el área de interés (Figura 82). A estos se los empleó como la verdad del terreno para cotejar las superficies inundadas determinadas por dichos algoritmos. Es necesario indicar que la superficie total de cada cubeta, expresada en Hectáreas, fue determinada a partir de la interpretación visual de la imagen óptica Sentinel 2 adquirida el día 10/01/2017. Además, se considera en este análisis que las mismas se encontraban anegadas en el 100% de su superficie. En este punto se debe comentar que aunque es posible que algunos lotes, presentes en los bajos, no estén completamente anegados, esta elección permite una evaluación del rendimiento de los algoritmos sobre áreas amplias, disminuyendo entonces la influencia de casos particulares. Estos últimos pueden ser importantes cuando se evalúan los algoritmos sobre blancos pequeños, de los cuales se conocen muy bien sus características, pero no constituyen una muestra estadística representativa para la evaluación de los métodos de clasificación utilizados.




FIGURA 82: Cubetas inundadas digitalizadas sobre la imagen óptica RGB-118a5.

A continuación, se pueden observar en las Tablas 8 y 9 las superficies inundadas en cada cubeta, derivadas desde ambos mecanismos de dispersión (especular y doble rebote), determinadas por cada técnica considerada.

TABLA 8: Superficies inundadas en la cubeta 1 derivadas de los mecanismos de dispersión especular y de doble rebote, determinadas por los distintos algoritmos.

ALGORITMOS	CUBETA 1 (Sup. 12263,71 Ha)				
	Sup. Especular (Ha)	(%)	Sup. Doble Rebote (Ha)	(%)	Sup. Total (Ha)
Umbral Manual	4950,41	69	2186,13	31	7136.54
NDFI NDFVI	4247,19	77	1287,47	23	5534.66
NDFI NDFVI - Serie	3952,51	85	712,69	15	4665.20
Cociente VV/VH - GRD	3822,33	78	1059,64	22	4881.97
Cociente VV/VH - SLC	7220,44	98	135,46	2	7355.90
H - Alfa	2570,59	58	1896,74	42	4467.33
H - Alfa - Clasif.	4545,14	71	1885,17	29	6430.31

TABLA 9: Superficies inundadas en la cubeta 2 derivadas de los mecanismos de dispersión especular y de doble rebote, determinadas por las distintos algoritmos.

ALGORITMOS	CUBETA 2 (Sup. 4139,82 Ha)				
	Sup. Especular (Ha)	(%)	Sup. Doble Rebote (Ha)	(%)	Sup. Total (Ha)
Umbral Manual	1880,88	75	629,14	25	2510.02
NDFI NDFVI	1687,35	83	353,60	17	2040.95
NDFI NDFVI - Serie	1464,12	87	211,41	13	1675.53
Cociente VV/VH - GRD	1571,05	84	296,57	16	1867.62
Cociente VV/VH - SLC	2412,98	94	152,09	6	2565.07
H - Alfa	897,65	62	549,18	38	1446.83
H - Alfa - Clasif.	1822,71	77	555,70	23	2378.41

Para comparar el desempeño de los diferentes algoritmos de clasificación aplicados en la detección de la superficie inundada en ambas cubetas a partir de los dos mecanismos de interacción predominantes, se determinó la superficie total

inundada, considerando ambas cubetas, derivada de cada mecanismo de dispersión (especular y doble rebote), ver Tabla 10.

TABLA 10: Superficie total inundada en ambas cubetas detectada a partir de la dispersión especular y de doble rebote por los distintos algoritmos y el porcentaje (%) correspondiente.

ALGORITMOS	Dispersión Especular		Dispersión Doble Rebote	
	Superficie (Ha)	Sup. (%)	Superficie (Ha)	Sup. (%)
Umbral Manual	6831,29	71	2815,27	29
NDFI NDFVI	5934,54	78	1641,07	22
NDFI NDFVI - Serie	5416,63	85	924,10	15
Cociente VV/VH - GRD	5393,38	80	1356,21	20
Cociente VV/VH - SLC	9633,42	97	287,55	3
H - Alfa	3468,24	59	2445,92	41
H - Alfa - Clasif.	6367,85	72	2440,87	28
	Promedio %:	78	Promedio %:	22

Al observar la Tabla 10 surge que los algoritmos utilizados, determinaron la superficie total inundada en las dos cubetas con porcentajes variables en cuanto a los aportes de los mecanismos de dispersión. En el caso del especular el rango varía de 59 a 97% y para el de doble rebote de 3 a 41%. Sin embargo, al efectuar el promedio de los porcentajes con los que contribuye cada mecanismo de dispersión, detectado por las diversas técnicas, se observa que la dispersión especular aporta un 78% del total y la de doble rebote un 22%. Con lo cual se aprecia la importancia de la detección de este último mecanismo de interacción en áreas agrícolas anegadas en donde los cultivos ocultan el agua de la inundación.

A partir del análisis de los resultados observados en las Tablas 8, 9 y 10; se decide aplicar un nuevo algoritmo de clasificación supervisado, al cual se denominó **Mixto**, que resultó simplemente de combinar, a través de una suma, los resultados obtenidos por los dos algoritmos que detectaban la mayor superficie especular, por un lado, y la de doble rebote, por otro, siendo estos el Cociente VV/VH - SLC y el Umbral Manual, respectivamente. Entonces, en el algoritmo **Mixto** la superficie total inundada resulta de:

Sup. Total Inundada = Cociente VV/VH-SLC (esp.) + Umbral Manual (doble rebote)

A continuación, se muestra en la Tabla 11 la superficie total inundada en cada cubeta (especular + doble rebote) detectada por los diversos algoritmos aplicados sobre las imágenes radar Sentinel 1, incluyendo el Mixto (Anexo II). También, se agrega en este análisis la superficie inundada derivada por el índice óptico de agua (NDWI) obtenido de la imagen Sentinel 2. Es importante recordar que generalmente las imágenes ópticas no se pueden utilizar durante una inundación debido a la presencia de nubes. Sin embargo, dado que en este caso se cuenta con una, el NDWI derivado de la misma es presentado principalmente como una referencia.

TABLA 11: Superficie total inundada en cada cubeta determinada por las distintos algoritmos

ALGORITMOS	CUBETA 1 (Sup. 12263,71 Ha)	CUBETA 2 (Sup. 4139,82 Ha)
NDWI (óptico)	9350,70	3284,68
Umbral Manual	7136,54	2510,02
NDFI NDFVI	5534,66	2040,95
NDFI NDFVI - Serie	4665,20	1675,53
Cociente VV/VH - GRD	4881,97	1867,62
Cociente VV/VH - SLC	7355,90	2565,07
H - Alfa	4467,33	1446,83
H - Alfa - Clasif.	6430,31	2378,41
Mixto	8645,43	2955,01

Continuando, la Tabla 12 permite apreciar el porcentaje de inundación detectado por cada algoritmo en las dos cubetas analizadas.

TABLA 12: Porcentaje de la superficie inundada en cada cubeta derivado de los algoritmos

ALGORITMOS	Cubeta 1 (%)	Cubeta 2 (%)	% Promedio
NDWI (óptico)	76,25	79,28	78
Umbral Manual	58,19	60,58	59
NDFI NDFVI	45,13	49,26	47
NDFI NDFVI - Serie	38,04	40,44	39
Cociente VV/VH - GRD	39,81	45,08	42
Cociente VV/VH - SLC	59,98	61,91	61
H - Alfa	36,43	34,92	36
H - Alfa - Clasif.	52,43	57,41	55
Mixto	70,50	71,38	71

A partir de la comparación del porcentaje promedio de inundación que detecto cada algoritmo de clasificación en ambas cubetas es posible establecer un orden decreciente de dichos métodos empleados, ver tabla 13.

TABLA 13: Orden decreciente del porcentaje promedio de inundación expresado por cada algoritmo en las dos cubetas consideradas.

ALGORITMOS	% Promedio
NDWI (óptico)	78
Mixto	71
Cociente VV/VH - SLC	61
Umbral Manual	59
H - Alfa - Clasif.	55
NDFI NDFVI	47
Cociente VV/VH - GRD	42
NDFI NDFVI - Serie	39
H - Alfa	36

Del análisis de la Tabla 13 surge que el algoritmo que determinó en mayor porcentaje la superficie anegada en ambas cubetas fue la del índice óptico NDWI con un 78%. En este sentido, queda claro que este índice se obtuvo por contar con una imagen óptica (Sentinel 2) adquirida durante el evento climático extremo el día 10/01/2017, lo cual no es una situación usual durante este tipo de eventos dado que las condiciones climáticas adversas condicionan fuertemente la toma de tales imágenes.

Por el contrario, las imágenes radar pueden ser adquiridas en tales circunstancias dando, por lo tanto, la posibilidad de obtener la superficie inundada. En este caso, fue el algoritmo de clasificación Mixto el cual derivó la superficie inundada de las cubetas con mayor porcentaje (71%); luego siguió el Cociente VV/VH - SLC (61%) y en tercer lugar el Umbral Manual (59%). Se observa como el algoritmo Mixto al utilizar los resultados derivados de los otros dos para la dispersión especular y la de doble rebote, respectivamente, permite mejorar la detección de la superficie inundada quedando un 7% por debajo del índice óptico (78%).

7.2 VALIDACIÓN DE LOS MÉTODOS DE CLASIFICACIÓN

Para validar los métodos de clasificación utilizados, se aplicaron los mismos en toda el área de estudio con objeto de determinar los sectores inundados (clase agua) y los no inundados (clase no agua). En la Tabla 14 se pueden apreciar las áreas determinadas por los distintos algoritmos sobre el área de estudio, cuya superficie total es de 118.082,44 Ha. También se observan los porcentajes de la superficie inundada, detectados por cada método, en el área de interés. Del estudio de esta Tabla se desprenden los algoritmos que mostraron la mayor superficie inundada, estos fueron: el índice óptico NDWI (24,19%), Mixto (19,24), NDFI NDFVI (16,33%), Umbral Manual (15,63%) y H-Alfa - Clasif. (13,61%).

TABLA 14: Superficies inundada y no inundada determinadas por los algoritmos en al área de estudio dispuestas en orden decreciente.

ALGORITMOS	Sup. No Inundada (Ha)	Sup. Inundada (Ha)	Sup. Inundada (%)
NDWI (óptico)	84965,60	27117,63	24,19
Mixto	95362,07	22724,58	19,24
NDFI NDFVI	98887,37	19285,35	16,33
Umbral Manual	99719,34	18451,00	15,63
H - Alfa - Clasif,	102093,95	16071,67	13,61
Cociente VV/VH - SLC	102783,06	15372,56	13,02
NDFI NDFVI - Serie	103798,79	14373,94	12,17
H - Alfa	104038,95	14113,31	11,95
Cociente VV/VH - GRD	107206,96	10963,93	9,28

A continuación, se efectuó la validación de las imágenes binarias (agua y no agua), derivadas de los algoritmos empleados, utilizando la matriz de error. Como áreas de control o de verdad del terreno, se emplearon las muestras obtenidas en campo (19) y otras (131) adquiridas sobre la imagen óptica Sentinel 2 RGB-118a5 (del 10/01/2017) a partir de la interpretación visual, dando un total de 150 áreas de test, ver Figura 83. Las mismas corresponden a las dos clases de interés (agua y no agua) que se encuentran presentes en las imágenes binarias a controlar.




FIGURA 83: Áreas de control (rojo) para ejecutar la matriz de error de cada algoritmo aplicado, superpuestas a la imagen óptica Sentinel 2 RGB-118a5.

A continuación, se muestran en las Tablas 15 a 23 las matrices de error ejecutadas para cada algoritmo de clasificación considerado, ver también Anexo III para más detalles. En las mismas se observan las dos clases validadas (agua y no agua) y las Exactitudes del Productor y del Usuario dadas en porcentaje (%), las mismas luego serán relacionadas con los errores de Omisión y Comisión de la siguiente manera:

$$\text{Error de Omisión (\%)} = 100 - \text{Exactitud del Productor (\%)}$$

$$\text{Error de Comisión (\%)} = 100 - \text{Exactitud del Usuario (\%)}$$

TABLA 15: Matriz de error del algoritmo NDWI

	> ERROR MATRIX (pixelcount)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	17222	7318	24540
Agua	0	28409	28409
Total	17222	35727	52949
Exac. Productor [%]	100.0000	51.6970	
Exac. Usuario [%]	70.1793	100.0000	

TABLA 16: Matriz de error del algoritmo **Mixto**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	17505	4421	21926
Agua	593	32921	33514
Total	18098	37342	55440
Exac. Productor [%]	99.4746	53.7236	
Exac. Usuario [%]	79.8367	98.2306	

TABLA 17: Matriz de error del algoritmo **Umbral Manual**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	16928	6077	23005
Agua	295	29647	29942
Total	17223	35724	52947
Exac. Productor [%]	99.7529	40.9522	
Exac. Usuario [%]	73.5840	99.0148	

TABLA 18: Matriz de error del algoritmo **NDFI NDFVI**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	16665	9432	26097
Agua	558	26296	26854
Total	17223	35728	52951
Exac. Productor [%]	99.3694	34.5717	
Exac. Usuario [%]	63.8579	97.9221	

TABLA 19: Matriz de error del algoritmo **NDFI NDFVI Serie**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	16249	14431	30680
Agua	974	21297	22271
Total	17223	35728	52951
Exac. Productor [%]	98.8694	21.9681	
Exac. Usuario [%]	52.9628	95.6266	

TABLA 20: Matriz de error del algoritmo **Cociente VV/VH - GRD**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	17125	14376	31501
Agua	98	21352	21450
Total	17223	35728	52951
Exac. Productor [%]	99.9141	18.2385	
Exac. Usuario [%]	54.3634	99.5431	

TABLA 21: Matriz de error del algoritmo **Cociente VV/VH - SLC**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	34527	21974	56501
Agua	384	50056	50440
Total	34911	72030	106941
Exac. Productor [%]	99.8140	27.6222	
Exac. Usuario [%]	61.1087	99.2387	

TABLA 22: Matriz de error del algoritmo **H - Alfa**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	34113	15049	49162
Agua	798	57000	57798
Total	34911	72049	106960
Exac. Productor [%]	98.7843	20.1196	
Exac. Usuario [%]	48.5118	95.5991	

TABLA 23: Matriz de error del algoritmo **H - Alfa - Clasif**

	> ERROR MATRIX (pixel count)		
	> Referencia		
V_Classified	No Agua	Agua	Total
No Agua	34066	15139	49205
Agua	800	56971	57771
Total	34866	72110	106976
Exac. Productor [%]	99.6861	33.5356	
Exac. Usuario [%]	69.2328	98.6152	

Continuando, en la Tabla 24 es posible observar los errores de Omisión y Comisión cometidos por cada algoritmo. Estos son importantes para conocer cuánto de menos ha detectado la inundación (error de omisión) o cuanto en exceso lo ha hecho (error de comisión) cada uno de los mismos.

También, la Tabla 24 permite visualizar al algoritmo Mixto como siendo el que posee el menor error de omisión (46,3%) cuando comparado con los demás algoritmos aplicados a las imágenes SAR e inclusive al índice óptico NDWI (48,3%). A su vez, presenta un error de comisión de la clase “no agua” de 20,2% y de 1,8% para la categoría “agua”.

TABLA 24: Errores de Omisión y Comisión de cada algoritmo presentados en orden creciente

ALGORITMOS	Errores (%)	No Agua	Agua
Mixto	Omisión	0,5	46,3
	Comisión	20,2	1,8
NDWI (óptico)	Omisión	0,0	48,3
	Comisión	29,8	0,0
Umbral Manual	Omisión	0,2	59,0
	Comisión	26,4	1,0
NDFI NDFVI	Omisión	0,6	65,4
	Comisión	36,1	2,1
H - Alfa - Clasif,	Omisión	0,3	66,5
	Comisión	30,8	1,4
Cociente VV/VH - SLC	Omisión	0,2	72,4
	Comisión	38,9	0,8
H - Alfa	Omisión	1,2	79,9
	Comisión	51,5	4,4
NDFI NDFVI Serie	Omisión	1,1	78,0
	Comisión	47,0	4,4
Cociente VV/VH - GRD	Omisión	0,1	81,8
	Comisión	45,6	0,5

Del análisis del error de omisión (Tabla 24) de los algoritmos aplicados a las imágenes SAR, surge que en todos ellos dicho error para la clase “agua” es alto y va

desde 46,3% (Mixto) a 81,8% (Cociente VV/VH - GRD), es decir, los algoritmos están omitiendo en ese porcentaje la detección de áreas inundadas. También, es elevado el error de comisión para la clase “no agua” encontrándose el mismo en el rango de 20,2% (Mixta) a 51,5% (H - Alfa), esto es, existe un exceso en la determinación de áreas no inundadas, lo cual es concordante con el déficit u omisión de la clase “agua”. Sin embargo, se observa que el algoritmo que presenta los menores porcentajes de error, tanto de omisión (clase agua) como de comisión (clase no agua) es el Mixto.

Por lo tanto, de esta validación queda claro que los algoritmos aplicados omiten la detección de áreas inundadas y al mismo tiempo detectan en exceso las áreas no inundadas, indicando que la superficie total inundada determinada por los mismos es menor a lo señalado por las áreas de control de la verdad del terreno. Por el contrario, los algoritmos mostraron un error de omisión muy bajo (de 0,2% a 1,2%) para la clase “no agua”. También, es muy pequeño el error de comisión (de 0,5% a 4,4%) de la categoría “agua”, señalando que la misma no es sobreestimada por los métodos considerados. A continuación, la Tabla 25 muestra los índices de fiabilidad global (%) y Kappa determinados por la matriz de confusión para cada algoritmo.

TABLA 25: Índices de Fiabilidad global (%) y Kappa de cada algoritmo empleado ordenados de manera decreciente según el primero.

ALGORITMOS	Fiabilidad global [%]	Kappa
Mixto	83,4	0,6
Umbral Manual	77,6	0,5
NDWI (óptico)	77,4	0,5
H - Alfa - Clasif,	73,2	0,4
NDFI NDFVI	69,4	0,4
Cociente VV/VH - SLC	66,1	0,3
Cociente VV/VH - GRD	58,6	0,2
NDFI NDFVI - Serie	58,2	0,2
H - Alfa	54,1	0,2

En la Tabla 25 se puede observar un índice de Fiabilidad global alto (83,4%) para el algoritmo denominado Mixto. Este supera a los demás algoritmos aplicados a las imágenes radares e inclusive al obtenido por el índice óptico NDWI (77,4%). En segundo lugar se encuentra el algoritmo Umbral Manual (77,6%) y en tercero el H-

Alfa - Clasif. (73,2%). Todas los demás métodos de clasificación tienen valores del índice de fiabilidad global inferiores a las mencionadas pero superiores al 50%.

En cuanto al índice Kappa, este presenta un valor alto solo para el algoritmo Mixto (0,6), alcanza un valor medio para los de Umbral Manual (0,5) y el óptico NDWI (0,5); tiene un valor regular para: H - Alfa - Clasif. (0,4), NDFI NDFVI (0,4) y Cociente VV/VH - SLC (0,3); siendo bajo (0,2) para las restantes tres.

Finalmente, del análisis de los indicadores obtenidos de la aplicación de las matrices de error, tales como: error de omisión, error de comisión, fiabilidad global y Kappa (Tablas 24 y 25), resulta que los algoritmos de clasificación más indicados para la detección de las áreas inundadas son: Mixto, Umbral Manual y H - Alfa - Clasif.

A continuación, la Figura 84 muestra la información generada a partir de la aplicación del algoritmo seleccionado “Mixto” sobre la imagen SAR del día 14/01/2017, ver también Anexo IV. La misma corresponde a una cartografía temática de áreas inundadas, en el sector bajo estudio, ejecutada según la norma cartográfica de la Provincia de Santa Fe (SCIT-UNL, 2007) [90].

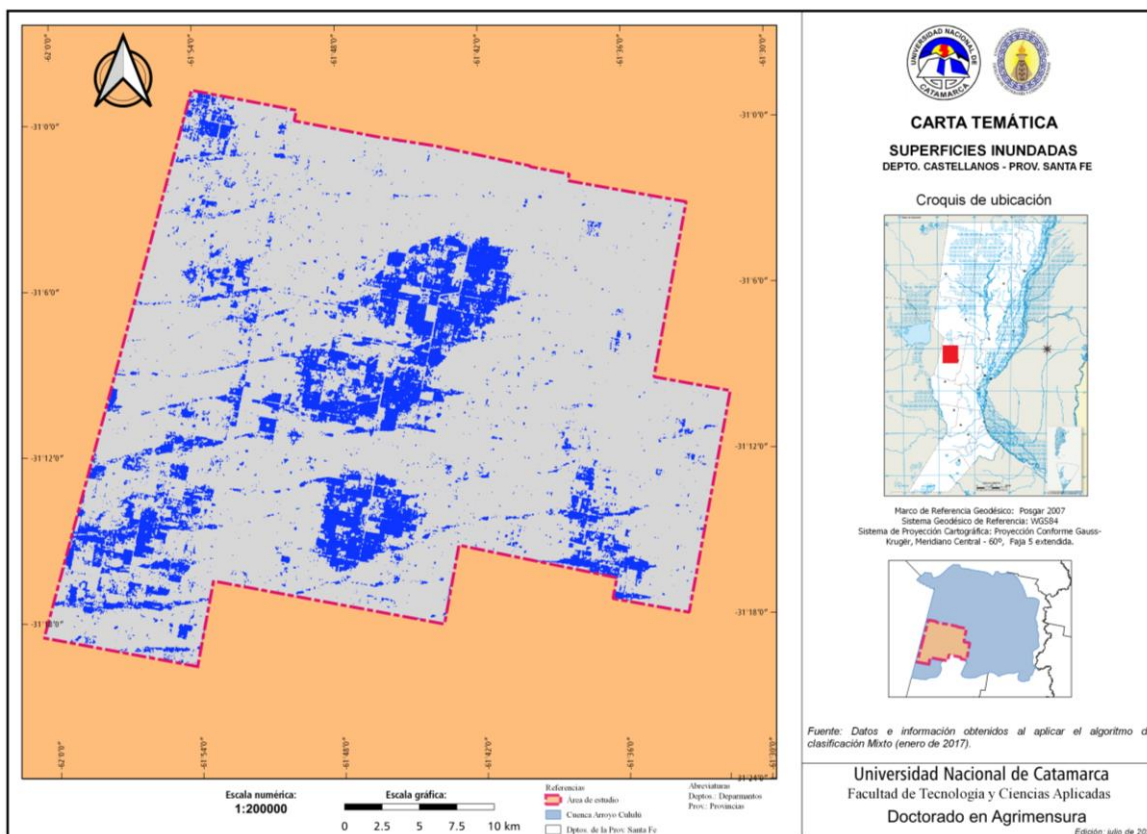


FIGURA 84: Cartografía temática de superficies inundadas en el área de estudio.

Por último, se muestra en la Figura 85 una posible aplicación de la cartografía temática de áreas inundadas. En la misma se observa la superposición en un sector del área de estudio, correspondiente al Distrito Presidente Roca, del parcelario rural del Servicio de Catastro e Información Territorial de la Prov. de Santa Fe. Con esto la institución provincial que lo requiera podrá tener acceso a los datos catastrales de la parcela afectada por la inundación para realizar las acciones que correspondan.

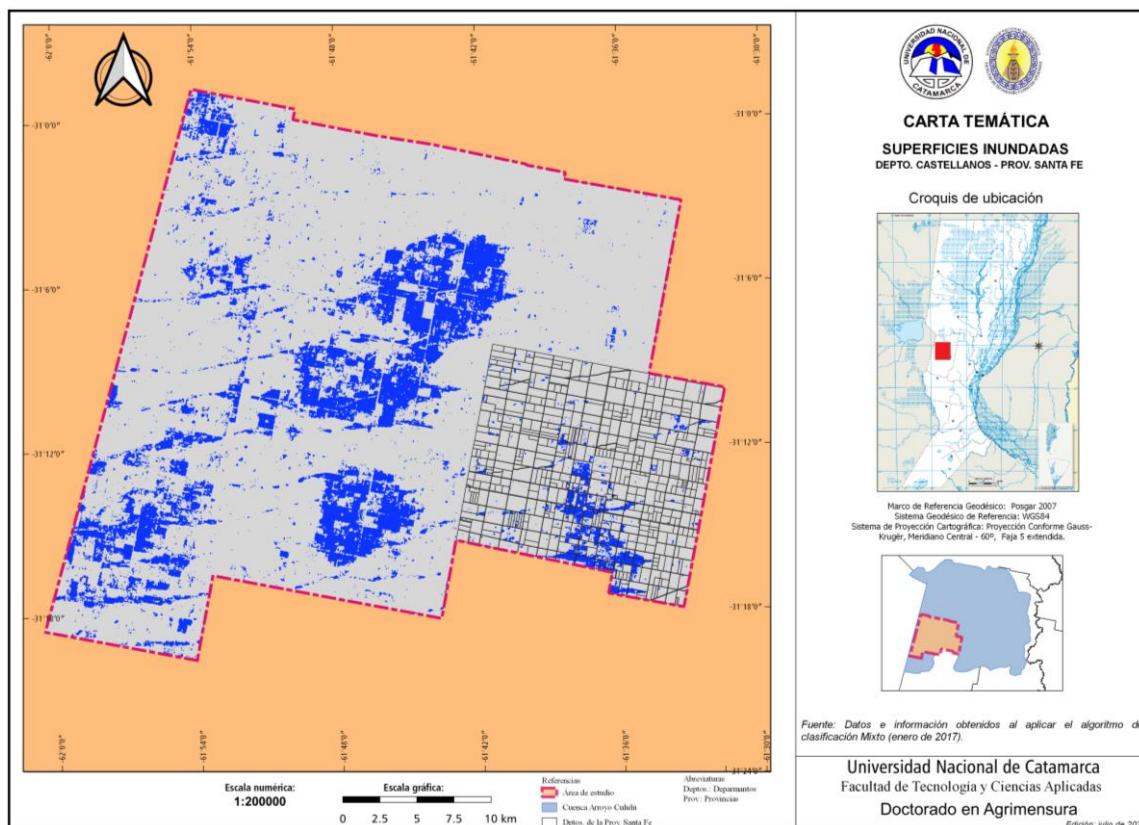


FIGURA 85: Superposición del parcelario rural a la cartografía temática de áreas inundadas en un sector del área de estudio.

8. CONCLUSIONES

En relación al objetivo general de esta investigación, se concluye que se consiguió desarrollar un algoritmo para la identificación de las superficies inundadas (abiertas y con vegetación) a partir del uso de imágenes SAR en banda C y polarización dual (VV - VH). Este algoritmo tiene una performance similar a la clasificación supervisada con imágenes ópticas, las cuales en general no se pueden utilizar durante un evento extremo debido a la presencia de nubes. Además el algoritmo fue testeado sobre un área de estudio amplia (1180,82 km²) durante un evento climático extremo y comparado con otros disponibles en la literatura. Se destaca que la identificación de superficies con vegetación inundada es un problema abierto para la comunidad científica y este estudio intenta contribuir en este sentido.

Fue posible diferenciar algunos lotes inundados con cobertura de cultivos, en los cuales estos cubrían el agua. Particularmente, en los lotes con maíz se verificó la presencia del mecanismo de dispersión de doble rebote entre el agua y los tallos de las plantas. Sin embargo, este mecanismo de interacción no pudo ser comprobado en otros cultivos presentes en el área de estudio, tales como: soja, girasol y sorgo.

Se realizó la comparación de los ocho algoritmos aplicados a las imágenes SAR, siete de ellos extraídos de la literatura y uno desarrollado en la investigación, y de un índice óptico (NDWI) sobre dos cubetas o bajos considerados como áreas inundadas de control. De la misma surgió que los métodos: Mixto, Cociente VV/VH-SLC y Umbral Manual; fueron, de los aplicados a las imágenes SAR, los que consiguieron determinar en mayor porcentaje el área inundada en dichos bajos, 71%, 61% y 59% respectivamente. Sin embargo, aunque el índice óptico mencionado consiguió discriminar en mayor porcentaje las áreas anegadas (78%), es necesario considerar que generalmente no está disponible ante situaciones climáticas adversas debido a la presencia de cobertura de nubes.

En cuanto a la validación de los métodos sobre todo el área de estudio, se aplicó la matriz de error considerando un número importante de muestras de la verdad del terreno (150). Se emplearon diversos indicadores generados por la misma, obteniendo un índice de fiabilidad global de 83,4% para el método Mixto, 77,6% para

Umbral Manual y 73,2% para H-Alfa - Clasif. Por lo tanto, a partir de dicha evaluación se seleccionó el algoritmo "Mixto".

Las principales ventajas del método Mixto son:

- Simplicidad y rapidez, desde el punto de vista computacional, requiere de un procesamiento mínimo que solo precisa contar con una imagen SAR que puede ser adquirida por diversos sensores;
- Explotación de los conjuntos de datos de observación de la tierra (Big Data EO), tales como, los adquiridos por el programa Copernicus de la Agencia Espacial Europea (ESA);
- Fácil selección de umbrales;
- Capacidad de extraer tanto las superficies abiertas inundadas con agua "libre", como la vegetación inundada donde el agua es cubierta por ciertos cultivos. Esto último constituye información generalmente no reportada por los índices derivados de imágenes ópticas, sin embargo, es crucial para estimar los impactos en la actividad agropecuaria.

Otra ventaja del algoritmo seleccionado, es que el mismo permite generar los mapas temáticos de inundación a través de la aplicación de un procedimiento sencillo de cuatro pasos, que utiliza como insumo básico una imagen SAR de descarga gratuita y se ejecuta a través de un programa de acceso libre. Siendo, por lo tanto, el método recomendado para su utilización por parte de las diversas instituciones del estado de la provincia de Santa Fe que intervienen ante tales situaciones de emergencia hídrica.

Por último, se recomiendan un conjunto de actividades a futuro que pueden llevar a una mejora del algoritmo:

- Incrementar el número de muestras en campo incluyendo diversos cultivos y pastizales en el (no deseable) caso de otros eventos extremos;
- Refinar la determinación de los umbrales cuando otros datos de campo sean disponibles;
- Utilizar imágenes SAR tomadas en banda L (mayor penetración en la vegetación) con polarización cuádruple (explotación completa de la técnica PolSAR);
- Uso de una serie de imágenes SAR multifrecuencia (X, C, L y P).

REFERENCIAS BIBLIOGRÁFICAS

- [1] Shen X., D. Wang, K. Mao, E. Anagnostou and Y. Hong, “Inundation Extent Mapping by Synthetic Aperture Radar: A Review” , Remote Sensing, 11, 879, 2019.
- [2] Pulvirenti L., N. Pierdicca, M. Chini, and L. Guerriero, “Monitoring Flood Evolution in Vegetated Areas Using COSMO-SkyMed Data: The Tuscany 2009 Case Study.” IEEE Journal Sel Topics Applications Earth Observations Remote Sensing 6 (4): 1807-1816. doi:10.1109/JSTARS.2012.2219509, 2013.
- [3] Chapman B., K. McDonald, M. Shimada, A. Rosenqvist, R. Schroeder, and L. Hess, “Mapping Regional Inundation with Spaceborne L-Band SAR” , Remote Sensing 7 (5): 5440-5470. doi:10.3390/rs70505440, 2015.
- [4] Pulvirenti L., M. Chini, N. Pierdicca, and G. Boni. “Use of SAR Data for Detecting Floodwater in Urban and Agricultural Areas: The Role of the Interferometric Coherence.” IEEE Transactions Geoscience Remote Sensing 54 (3): 1532-1544. doi:10.1109/TGRS.2015.2482001, 2016.
- [5] Leva P. y García M. S., “Bases Conceptuales para el Ordenamiento Territorial en el Medio Rural” , Gobierno y UU NN de las Provincias de la Región Centro. Capítulo 25: Clima, pp. 473-482, 2013.
- [6] MAH, UNL, INA, INTA, “Influencia de los Cambios Físicos y Climáticos en el Regimen de escurrimiento del Río Salado - Tramo Inferior” . Informe Final Convenio MAH con UNL-INA-INTA, Santa Fe, Noviembre de 2007.
- [7] Servicio Meteorológico Nacional - SMN, “Estadísticas Meteorológicas” , Buenos Aires, 2008.
- [8] Krohling D. y Brunetto E., “Bases Conceptuales para el Ordenamiento Territorial en el Medio Rural” , Gobierno y UU NN de las Provincias de la Región Centro. Capítulo 26: Marco Geológico y Geomorfológico de la Cca. Cululú, pp. 483-511, 2013.
- [9] Iriondo M., “Estudio Geomorfológico de la Cuenca del Río Salado en Santa Fe”, Convenio UNL-INCYTH, Santa Fe, 1983.
- [10] Pasotti P., “Interpretación de algunos rasgos morfológicos en el centro-oriente de la llanura pampeana en la provincia de Santa Fe” . UNR, Rosario, 1969.
- [11] Iriondo M. y E. Drago, “The headwater hydrographic characteristics of larga plains: the Pampa case”, Ecohydrology Hydrology, vol. 4, n° 1, pp. 7-16, 2004.

- [12] Pilatti M., “Bases Conceptuales para el Ord. Territorial en el Medio Rural”, Gob. y Univ. Nac. de las Prov. de la Región Centro. Cap. 28: Suelos, tierras y capacidad productiva de los cultivos en la Cca. del Cululú, pp. 545-568, 2013.
- [13] Paoli C., Rosana Hammerly, Ricardo Giacosa, Dora Sosa, Pablo Cacik y Antonio Villordo, “Bases Conceptuales para el Ord. Territorial en el Medio Rural”, Gob. y Univ. de las Prov. de la Región Centro. Cap. 24: Los cambios globales en el régimen hidrológico de la Cca. Cululú, pp. 449-471, 2013.
- [14] INTA, “Información productiva del área de influencia INTA Rafaela” , Año XII - n° 132, Rafaela, 2017.
- [15] Caracci C. y Faure D., “El Departamento y la inundación”, <https://inta.gob.ar/documentos/el-departamento-castellanos-y-la-inundacion>, 2017.
- [16] Ulaby F., Dobson M., and Bradley G., “ Radar reflectivity of bare and vegetation-covered soil Reading” , Massachusetts - USA, 1981.
- [17] Solbø S. and Solheim I., “Towards Operational Flood Mapping with Satellite SAR”, Norut Information Technology AS. Tromsø Science Park, N-9291 Tromsø, Norway, 2005.
- [18] Belmonte I. y Caamaño S., “Una aplicación basada en imágenes SAR para el monitoreo y prevención de inundaciones en Argentina” , Tesis, Fac. de Matemática, Astronomía y Física, Universidad Nacional de Córdoba, 2009.
- [19] Pulvirenti L., F. Marzano, N. Pierdicca, S. Mori and M. Chini, “Discrimination of Water Surfaces, Heavy Rainfall, and Wet Snow Using COSMO-SkyMed Observations of Severe Weather Events” , IEEE Transactions on Geoscience and Remote Sensing, vol. 52, n° 2, 2014.
- [20] Pulvirenti L., N. Pierdicca, G. Boni, M. Fiorini and R. Rudari, “Flood Damage Assessment Through Multitemporal COSMO-SkyMed Data and Hydrodynamic Models: The Albania 2010 Case Study” , IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 7, n° 7, 2014.
- [21] Pottier E. and Ferro-Famil L., “Forest applications with Polarimetry and Interferometry”, 8th Advanced Training Course on Land Remote Sensing, ESA, 2018.
- [22] Giustarini L., H. Vernieuwe, J. Verwaeren, M. Chini, R. Hostache, P. Matgen, N.E.C. Verhoest and B. De Baets, “Accounting for image uncertainty in SAR-

based flood mapping” , International Journal of Applied Earth Observation and Geoinformation, 34, pp. 70-77, 2015.

- [23] Boni G., L. Ferraris, L. Pulvirenti, G. Squicciarino, N. Pierdicca, L. Candela, A. Rita Pisani, S. Zoffoli, R. Onori, C. Proietti and P. Pagliara, “A Prototype System for Flood Monitoring Based on Flood Forecast Combined With COSMO-SkyMed and Sentinel-1 Data” , IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 9, no. 6, 2016.
- [24] Donezar-Hoyos U., Larrañaga-Urien, A., Tamés-Noriega, A., Sánchez-Gil, C., Albizua-Huarte, L., Ciriza-Labiano, del Barrio-Arellano “ Aplicación de imágenes Sentinel-1 y Sentinel-2 en la detección y delineación de información de crisis de desastres naturales en el marco de los servicios Copernicus EMS”, Revista de Teledetección, vol. 50, pp. 49-57, 2017.
- [25] Clement M.A., C.G. Kilsby and P. Moore, “Multi-temporal synthetic aperture radar flood mapping using change detection ” , Journal of Flood Risk Management, 2017.
- [26] Cooper E.S., S.L. Dance, J. García-Pintado, N.K. Nichols and P. Smith “ Observation operators for assimilation of satellite observations in fluvial inundation forecasting” , Hydrology and Earth System Sciences Discussions, 2018.
- [27] Benoudjit A. and R. Guida, “A Novel Fully Automated Mapping of the Flood Extent on SAR Images Using a Supervised Classifier” , Remote Sensing, 11, 779; doi:10.3390/rs11070779, 2019.
- [28] Aldhshan S.R.S., O. Zubair Mohammed and H.Z. Mohd. Shafri, “Flash flood area mapping using sentinel-1 SAR data: a case study of eight upazilas in Sunamganj district, Bangladesh” , IOP Conf. Series: Earth and Environmental Science, 2019.
- [29] Reksten J. H., A-B. Salberg and R. Solberg, “Flood detection in Norway based on Sentinel-1 SAR imagery ” , The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-3/W8, 2019.
- [30] Debusscher B. and F. Van Coillie, “Object-Based Flood Analysis Using a Graph-Based Representation” , Remote Sensing, 11, 1883. 2019.
- [31] Cao H., H. Zhang, C. Wang and B. Zhang, “Operational Flood Detection Using Sentinel-1 SAR Data over Large Areas” , Water, 11, 786, 2019.

- [32] Ji K. and Wu Y., “Scattering Mechanism Extraction by a Modified Cloude-Pottier Decomposition for Dual Polarization SAR” , *Remote Sensing* 7, 7447-7470, 2015.
- [33] Huang M. and S. Jin, “Rapid Flood Mapping and Evaluation with a Supervised Classifier and Change Detection in Shouguang Using Sentinel-1 SAR and Sentinel-2 Optical Data” , *Remote Sensing*, 12, 2073, 2020.
- [34] Zhang M., F. Chen, D. Liang, B. Tian and A. Yang, “Use of Sentinel-1 GRD SAR Images to Delineate Flood Extent in Pakistan”, *Sustainability*, 12, 5784, 2020.
- [35] Kuntla S. K. and P. Manjusree, “Development of an Automated Tool for Delineation of Flood Footprints from SAR Imagery for Rapid Disaster Response: A Case Study” , *Journal of the Indian Society of Remote Sensing*, 2020.
- [36] Dasgupta A., P.K. Thakur, and P.K. Gupta, “Potential of SAR-derived flood maps for hydrodynamic model calibration in data 2 scarce regions”, *Journal of Hydrologic Engineering*, 2020.
- [37] Jennifer J.J., S. Saravanan and D. Abijith, “Integration of SAR and multi-spectral imagery in flood inundation mapping - a case study on Kerala floods 2018”, *ISH Journal of Hydraulic Engineering*, 2020.
- [38] Grings F. M., H. Karszenbaum, P. Ferrazzoli, L. Guerriero, M. Salvia, P. Kandus y P. Perna, “Recent results about asar observations of wetland marshes” , *Proc. Envisat Symposium 2007*, Montreux, Switzerland, 23-27, 2007.
- [39] Parmuchi Maria G., Haydee Karszenbaum y Patricia Kandus, “Mapping wetlands using multi-temporal RADARSAT-1 data and a decision-based classifier”, *Canadian Journal of Remote Sensing*, 28:2, 175-186, DOI: 10.5589/m02-014, 2002.
- [40] Kandus P., H. Karszenbaum, T. Pultz, G. Parmuchi & J. Bava., “Influence of Flood Conditions and Vegetation Status on the Radar Backscatter of Wetland Ecosystems”, *Canadian Journal of Remote Sensing*, 27:6, 651-662, DOI: 10.1080/07038992.2001.10854907, 2001.
- [41] Moncayo Silva P. J., “Estimación desde satélites de la fracción de área inundada en humedales fluviales de un sector de la planicie de inundación del Bajo Paraná, Argentina”, 2017.
- [42] Zamboni Graosque J. y L. A. Guasselli, “Principal component analysis of c-sar images for flood mapping - Santa Fe Province, Argentina”, *Revista Territorium*, N° 27 (II), 2020, ISSN: 0872-8941, 41-48, DOI: https://doi.org/10.14195/1647-7723_27-2_4, 2019.

- [43] Dinh D. A., B. Elmahrad, P. Leinenkugel and A. Newton, “Time series of flood mapping in the Mekong Delta using high resolution satellite images” , IOP Conf. Series: Earth and Environmental Science 266, 2019.
- [44] Huth J., U. Gessner, I. Klein, H. Yesou, X. Lai, N. Oppelt and C. Kuenzer, “ Analyzing Water Dynamics Based on Sentinel-1 Time Series - a Study for Dongting Lake Wetlands in China” , Remote Sensing, 12, 1761, 2020.
- [45] Pierdicca N., L. Pulvirenti, M. Chini, G. Boni, G. Squicciarino and L. Candela, “ Flood Mapping by SAR: Possible approaches to mitigate errors due to ambiguous radar signatures” , 2014.
- [46] Pulvirenti, L., N. Pierdicca, M. Chini, and L. Guerriero, “An Algorithm for Operational Flood Mapping from Synthetic Aperture Radar (SAR) Data Using Fuzzy Logic” Natural Hazards Earth Systems Sciences 11 (2): 529-540. doi:10.5194/nhess-11-529-2011, 2011.
- [47] Tsyganskaya V., Martinis S., Marzahn P. and Ludwig R., ” SAR-based detection of flooded vegetation - a review of characteristics and approaches” , International Journal of Remote Sensing, 39:8, 2255-2293, Doi:10.1080/01431161.2017.1420938, 2018.
- [48] Cian Fabio, Mattia Marconcini y Pietro Ceccato, “Normalized Difference Flood Index for rapid flood mapping: Taking advantage of EO big data” , Remote Sensing of Environment 209, pp. 712-730, 2018.
- [49] Martinez J., and T. Le Toan, “ Mapping of Flood Dynamics and Spatial Distribution of Vegetation in the Amazon Floodplain Using Multitemporal SAR Data ” , Remote Sensing of Environment 108 (3): 209 - 223. doi:10.1016/j.rse.2006.11.012, 2007.
- [50] Na, X. D., S. Y. Zang, C. S. Wu, and W. L. Li. “Mapping Forested Wetlands in the Great Zhan River Basin through Integrating Optical, Radar, and Topographical Data Classification Techniques” , Environmental Monitoring and Assessment 187 (11): 696. doi:10.1007/s10661-015-4914-7, 2015.
- [51] Baghdadi N., M. Bernier, R. Gauthier, and I. Neeson. “Evaluation of C-Band SAR Data for Wetlands Mapping” , International Journal of Remote Sensing 22 (1): 71-88. doi:10.1080/014311601750038857, 2001.
- [52] Hess L. L., J. M. Melack, S. Filoso, and Y. Wang. ” Delineation of Inundated Area and Vegetation along the Amazon Floodplain with the SIR-C Synthetic

- Aperture Radar” , IEEE Transactions Geoscience Remote Sensing 33 (4): 896-904. doi:10.1109/36.406675, 1995.
- [53] Richards J. A., Remote Sensing Digital Image Analysis. An Introduction. 5th ed. Berlin, New York: Springer, 2012.
- [54] Townsend P. A., “Relationships between Forest Structure and the Detection of Flood Inundation in Forested Wetlands Using C-Band SAR” , International Journal of Remote Sensing 23, 443 -460, doi:10.1080/01431160010014738. 2002.
- [55] Friedl M. A., and C. E. Brodley, “Decision Tree Classification of Land Cover from Remotely Sensed Data” , Remote Sensing of Environment 61 (3): 399-409. doi:10.1016/S0034-4257(97)00049-7, 1997.
- [56] Evans T. L., M. Costa, K. Telmer, and T. S. F. Silva, “Using ALOS/PALSAR and RADARSAT-2 to Map Land Cover and Seasonal Inundation in the Brazilian Pantanal” , IEEE Journal Sel Topics Applications Earth Observations Remote Sensing: 560-575. doi:10.1109/JSTARS.2010.2089042, 2010.
- [57] Robertson L. D., D. J. King, and C. Davies, “Object-Based Image Analysis of Optical and Radar Variables for Wetland Evaluation” , International Journal of Remote Sensing 36: 5811-5841. doi:10.1080/01431161.2015.1109727, 2015.
- [58] Augusteijn, M. F. and C. E. Warrender, “Wetland Classification Using Optical and Radar Data and Neural Network Classification” , International Journal of Remote Sensing 19 (8): 1545-1560. doi:10.1080/014311698215342, 1998.
- [59] Buckley J. J., and E. Eslami, “An Introduction to Fuzzy Logic and Fuzzy Sets” , Heidelberg: Physica-Verlag (Advances in soft computing), ISBN: 978-3-7908-1447-7, DOI: 10.1007/978-3-7908-1799-7, 2002.
- [60] Wang Y., “Seasonal Change in the Extent of Inundation on Floodplains Detected by JERS-1 Synthetic Aperture Radar Data” , International Journal of Remote Sensing 25: 2497-2508. doi:10.1080/01431160310001619562, 2004..
- [61] Giustarini L., Hostache R., Kavetski D., Chini M., Corato G., Schlaffer S., Matgen P., “Probabilistic flood mapping using synthetic aperture radar data” , IEEE Trans. Geosci. Remote Sens., 54, pp. 6958-6969, 2016.
- [62] Park H. S., and C. H. Jun, “A Simple and Fast Algorithm for K-Medoids Clustering ” , Expert Systems with Applications 36: 3336 - 3341. doi:10.1016/j.eswa.2008.01.039, 2009.

- [63] Morandeira N., F. Grings, C. Facchinetti, and P. Kandus, "Mapping Plant Functional Types in Floodplain Wetlands. An Analysis of C-Band Polarimetric SAR Data from RADARSAT-2" , *Remote Sensing* 8: 174. doi:10.3390/rs8030174, 2016.
- [64] Otsu, N, "A Threshold Selection Method from Gray-Level Histograms" , *IEEE Transactions on Systems, Man, and Cybernetics* 9: 62 - 66. doi:10.1109/TSMC.1979.4310076, 1979.
- [65] Kittler J., and J. Illingworth, " Minimum Error Thresholding " , *Pattern Recognition* 19 (1): 41-47. doi:10.1016/0031-3203(86)90030-0, 1986.
- [66] Shaoqing Z. and L. Xu, "The Comparative Study Of Three Methods Of Remote Sensing Image Change Detectio" , *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. XXXVII. Part B7, 2008.
- [67] Martinis S., "Automatic near real-time flood detection in high resolution X-band Synthetic Aperture Radar satellite data using context-based classification on irregular graphs" , Dissertation. Ludwig-Maximilians, Germany, 2010.
- [68] Twele A., Cao W., Plank S. and Martinis S., "Sentinel-1-based flood mapping: A fully automated processing chain" , *Int. J. Remote Sensing*, 37, pp. 2990-3004, 2016.
- [69] Santoro M. and Wegmüller U., " Multi-temporal sar metrics applied to map water bodies" , In *Proceedings of the 2012* , IEEE International Conference on Geoscience and Remote Sensing Symposium (IGARSS), Munich, Germany, pp. 5230-5233, 2012.
- [70] Green K., Kempka D., and Lackey Y., "Using Remote Sensing to Detect and Monitor Landcover and Land-use Change" , *Photogrammetric Engineering and Remote Sensing*, 60(3), pp. 331-337, 1994.
- [71] Nasirzadehdizaji R., D.E. Akyuz and Z. Cakir, "Flood mapping and permanent water bodies change detection using Sentinel SAR data" , *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-4/W18, 2019.
- [72] A. W. Jacob, F. Vicente-Guijalba, C. Lopez-Martinez, J.M. Lopez-Sanchez, M. Litzinger, H. Kristen, A. Mestre-Quereda, D. Ziółkowski, M. Lavalle, C. Notarnicola, G. Suresh, O. Antropov, S. Ge, J. Praks, Y. Ban, E. Pottier, J.J. Mallorquí Franquet, J. Duro and M.E. Engdahl, "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, 2020.

- [73] Giraldez Alberto, “Principios de Interferometria SAR” , CONAE, Mayo 2003.
- [74] Cloude Shane R, “ Radar Polarimetry and Interferometry: A Tutorial Introduction” , IEEE Geoscience and Remote Sensing Newsletter, 2004.
- [75] Del Valle Héctor, “Radares de Apertura Sintética y su sinergia con datos ópticos”, Curso 09, Centro Regional de Geomática (CEREGEO), Facultad de Ciencia y Tecnología (FCyT) Univer. Autónoma de Entre Ríos (UADER), 2017.
- [76] Cloude S. R. and E. Pottier, “An Entropy Based Classification Scheme for Land Applications of Polarimetric SAR”, IEEE Trans. Geos. and Rem. Sens., vol. 35, n° 1, 1997.
- [77] Aronoff S., “The map accuracy report: A user’ s view” , Photogrammetric Engineering and Remote Sensing, 48, pp. 1309-1312, 1982.
- [78] Story M. and Congalton R., “Accuracy assessment: A user’ s perspective” , Photogrammetric Engineering & Remote Sensing, vol. 52, 1986.
- [79] Chuvieco Emilio, “Teledetección Ambiental” , 3ra ed., vol. 1, Barcelona - España, 2007.
- [80] Chen Y., H. Xiufeng, J. Wang, and R. Xiao, “The Influence of Polarimetric Parameters and an Object-Based Approach on Land Cover Classification in Coastal Wetlands ” , Remote Sensing 6: 12575 - 12592. doi:10.3390/rs61212575, 2014.
- [81] Na X. D., S. Y. Zang, C. S. Wu, and W. L. Li, “Mapping Forested Wetlands in the Great Zhan River Basin through Integrating Optical, Radar, and Topographical Data Classification Techniques.” Environmental Monitoring and Assessment 187 (11): 696. doi:10.1007/s10661-015-4914-7, 2015.
- [82] Betbeder J., S. Rapinel, T. Corpetti, E. Pottier, S. Corgne, and L. Hubert-Moy, “ Multitemporal Classification of TerraSAR-X Data for Wetland Vegetation Mapping ” , Journal Applications Remote Sens 8: 83648. doi:10.1117/1.JRS.8.083648, 2014.
- [83] Rees, W., “Physical Principles of Remote Sensing (Topics in Remote Sensing) ” , Cambridge University Press - UK, 2005.

- [84] Mason D., Horritt M., Dall' Amico J., Scott T., and Bates P. "Improving river flood extent delineation from synthetic aperture radar using airborne laser altimetry" , IEEE Transactions on Geoscience and Remote Sensing, 45(12), pp. 3932-3943, 2007.
- [85] Edrosa M., "Aplicación de la Teledetección para el Monitoreo de Eventos Hídricos Superficiales mediante Imágenes Cosmo SkyMed" , Córdoba - Argentina, 2011.
- [86] Richards J., Woodgate P., and Skidmore A., "An explanation of enhanced radar backscattering from flooded forests" , International Journal of Remote Sensing, 8(7), pp. 1093-1100, 1987.
- [87] Salvia Mercedes, "Aporte de la teledetección al estudio del funcionamiento del Macrosistema Delta del Paraná: análisis de series de tiempo y eventos extremos (Tesis doctoral). Facultad de Ciencias Exactas y Naturales, Buenos Aires, 2010.
- [88] Grings F., Ferrazzoli P., Jacobo-Berlles J., Karszenbaum H., Tiffenberg J., Pratolongo,P. and Kandus P., "Monitoring flood condition in marshes using EM models and Envisat ASAR observations", Geoscience and Remote Sensing, 44(4), pp. 936-942, 2006.
- [89] Salvia M., Grings F., Ferrazzoli P., Rahmoune R., Barber M., and Karszenbaum H., "Monitoring flooded area fraction in floodplains of Paraná basin using passive and active microwave systems", Buenos Aires, 2010.
- [90] SCIT-UNL, "Norma Cartográfica de la Provincia de Santa Fe", Decreto N° 0884/07, Santa Fe, 50 p., 2007.

ANEXO I. Principales ventajas y desventajas de los métodos de clasificación supervisados y no supervisados

TABLA 26: Métodos de clasificación para detectar **Vegetación Inundada**

	Método (%)	Ventajas	Desventajas
SUPERVISADOS (88%)	Distancia (28%)	Simplicidad, disponibilidad y transparencia estadística (sin caja negra). Se adaptan fácilmente a diversos datos de entrada y a diferentes áreas de estudio.	No son adecuados para el análisis de datos de alta dimensión. Puede ser necesario tener que cambiar las reglas de clasificación predeterminadas para las clases ante el agregado de nuevos datos de entrada.
	Árbol de Decisión (25%)	No asumen una distribución particular de densidad de probabilidad de los datos de entrada. Flexibles y robustos con respecto a las relaciones no lineales y ruidosas de los datos de entrada. Requieren menor tiempo para el entrenamiento. Reglas de clasificación diseñadas por los usuarios se pueden cambiar iterativamente. Se pueden agregar nuevos ajustes o datos de entrada sin alterar las reglas de clasificación establecidas.	Es conveniente contar con experiencia previa para establecer las reglas de clasificación.
	Aprendizaje Automático (15%)	Mismas ventajas que el árbol de decisión dado que el Bosque aleatorio es un clasificador que contiene múltiples. Al promediar múltiples árboles de decisión, reduce el sobreajuste de cada uno de ellos. Son adecuados para aplicar sobre datos de alta dimensión y de diversas fuentes heterogéneas.	Demandan un gran conjunto de datos de entrada para establecer las reglas de clasificación. Requieren mayor tiempo para el entrenamiento. Dado que se desconoce la verdadera relación entre múltiples datos de entrada pondera los que presentan mayor correlación dejando relegados (menor importancia) al resto.
	Umbral Manual (13%)	Determinación simple del umbral desde el histograma. Extracción rápida y eficaz de las clases de interés.	Variabilidad espacial del umbral para grandes superficies inundadas debido a la heterogeneidad de la cobertura del suelo y a los parámetros del sistema satelital. Variabilidad temporal del umbral. Se debe determinar de manera particular para cada área de estudio.

	Lógica Difusa (5%)	Es posible integrar diferentes fuentes de datos. Se puede atribuir a los datos de entrada diferentes grados de pertenencia a un conjunto borroso (clases) a través de funciones que no emplean umbrales nítidos.	
	Detección de Cambios (2%)	Resalta los cambios temporales entre imágenes. Se aplican a las imágenes operaciones aritméticas simples (resta o división). Se puede aplicar a través de un índice.	Necesidad de una o varias imágenes de referencia previas al evento de inundación.
NO SUPERVISADOS (12%)	Agrupamientos (7%)	Establece relaciones entre los datos de entrada sin necesidad de contar con información previa (entrenamiento). Reduce los elementos a estudiar a partir de su agrupamiento. Produce una compensación del speckle. Fusiona clases similares y divide otras con mayor desvío estándar de manera iterativa.	
	Umbral Automático (2%)	Definen automáticamente el umbral en función del histograma. Extraen rápidamente las clases diferenciables en el histograma produciendo una visión general de las existentes.	Produce confusión entre las clases cuando se tienen histogramas superpuestos. Se aplica como una etapa previa dentro de un procedimiento de clasificación.
	Parámetros Polarimétricos (3%)	Creados específicamente para datos SAR de polarización cuádruple o doble. Extraen los mecanismos de dispersión.	Necesidad de contar con imágenes en formato SLC y de doble o cuádruple polarización.

TABLA 27: Métodos de clasificación para detectar **Superficies Abiertas Inundadas**

	Método (%)	Ventajas	Desventajas
SUPERVISADOS (60%)	Umbral Manual (22%)	Determinación simple del umbral desde el histograma. Extracción rápida y eficaz de las clases de interés. Proporciona resultados fiables y permite un rápido mapeo de las inundaciones.	Necesidad de un histograma bimodal para derivar el umbral entre agua y no agua. Variabilidad espacial del umbral para grandes superficies inundadas debido a la rugosidad del viento, heterogeneidad del terreno y a los parámetros del sistema satelital. Variabilidad temporal del umbral.

			Se debe determinar de manera particular para cada área de estudio.
	Detección de Cambios (21%)	Resalta los cambios temporales entre imágenes. Se aplican a las imágenes operaciones aritméticas simples (resta o división). Se puede aplicar a través de un índice de inundación. Mejora la precisión de los mapas de inundación en superficies abiertas.	Necesidad de una o varias imágenes de referencia previas al evento de inundación.
	Lógica Difusa (7%)	Es posible integrar diferentes fuentes de datos. Se puede atribuir a los datos de entrada diferentes grados de pertenencia a un conjunto borroso (clases) a través de funciones que no emplean umbrales nítidos.	
	Distancia (6%)	Simplicidad, disponibilidad y transparencia estadística (sin caja negra). Se adaptan fácilmente a diversos datos de entrada y a diferentes áreas de estudio.	No son adecuados para el análisis de datos de alta dimensión. Puede ser necesario tener que cambiar las reglas de clasificación predeterminadas para las clases ante el agregado de nuevos datos de entrada
	Aprendizaje Automático (2%)	Mismas ventajas que el árbol de decisión dado que el Bosque aleatorio es un clasificador que contiene múltiples. Al promediar múltiples árboles de decisión, reduce el sobreajuste de cada uno de ellos. Son adecuados para aplicar sobre datos de alta dimensión y de diversas fuentes heterogéneas.	Demandan un gran conjunto de datos de entrada para establecer las reglas de clasificación. Requieren mayor tiempo para el entrenamiento. Dado que se desconoce la verdadera relación entre múltiples datos de entrada pondera los que presentan mayor correlación dejando relegados (menor importancia) al resto.
	Análisis Visual (2%)	Alta precisión	Requiere mucho tiempo de ejecución
NO SUPERVISADOS (40%)	Segmentación (19%)	Identifica regiones de retrodispersión homogénea. Proporcionan información a nivel de objeto siendo menos afectadas por el speckle. Permite una cierta cantidad de heterogeneidad en la retrodispersión proveniente de un cuerpo de agua e incorpora métricas morfológicas (curvatura y tensión).	Utiliza la función de distribución Gamma, la cual no modela apropiadamente los datos SAR provenientes de regiones muy heterogéneas.

	Umbral Automático (15%)	Definen automáticamente el umbral en función del histograma. Produce rápidamente una clasificación de las superficies abiertas inundadas.	Produce confusión entre las clases cuando se tienen histogramas superpuestos.
	Coherencia (4%)	Resalta los cambios temporales entre imágenes.	Necesidad de una imagen de referencia previa en formato SLC.
	Parámetros Polarimétricos (2%)	Creados específicamente para datos SAR de polarización cuádruple o doble. Extraen los mecanismos de dispersión.	Necesidad de contar con una imagen SLC de polarización cuádruple o doble.

ANEXO II. Superficies inundadas de las cubetas determinadas por los métodos de clasificación

NDWI

Cubeta 01

Anchura en píxeles: 1133 (unidades por píxel 16,8257)

Altura en píxeles: 689 (unidades por píxel 20,1933)

Número total de píxeles: 780637

Valor	Número de píxeles	Área (m ²)
0	419325	
50	86018	29217080,20249365
255	275294	93507020,35928859

Cubeta 02

Anchura en píxeles: 608 (unidades por píxel 16,8014)

Altura en píxeles: 414 (unidades por píxel 20,2206)

Número total de píxeles: 251712

Valor	Número de píxeles	Área (m ²)
0	129759	44083492,20504604
50	25269	8584728,338915285
255	96684	32846803,38437158

Mixto

Cubeta 01

Anchura en píxeles: 1057 (unidades por píxel 17.9945)

Altura en píxeles: 771 (unidades por píxel 17.9931)

Número total de píxeles: 814947

Valor	Número de píxeles	Área (m ²)
50	111998	36262264.89628189
255	267019	86454344.81276715

Cubeta 02

Anchura en píxeles: 608 (unidades por píxel 16,8014)

Altura en píxeles: 414 (unidades por píxel 20,2206)

Número total de píxeles: 251712

Valor	Número de píxeles	Área (m ²)
50	36685	11877722.83492723
255	91267	29550064.87597939

Umbral Manual

Cubeta 01

Anchura en píxeles: 1133 (unidades por píxel 16,8257)

Altura en píxeles: 689 (unidades por píxel 20,1933)

Número total de píxeles: 780637

Valor	Número de píxeles	Área (m ²)
0	419326	
50	151204	51358313,31742018
255	210107	71365447,58196346

Cubeta 02

Anchura en píxeles: 608 (unidades por píxel 16,8014)

Altura en píxeles: 414 (unidades por píxel 20,2206)

Número total de píxeles: 251712

Valor	Número de píxeles	Área (m ²)
50	177830	60414826,0916263
255	73882	25100197,8367066

NDFI

Cubeta 01

Anchura en píxeles: 1133 (unidades por píxel 16,8257)

Altura en píxeles: 689 (unidades por píxel 20,1933)

Número total de píxeles: 780637

Valor	Número de píxeles	Área (m ²)
0	639739	
50	198366	67377470,87595241
255	162946	55346628,80409415

Cubeta 02

Anchura en píxeles: 608 (unidades por píxel 16,8014)

Altura en píxeles: 414 (unidades por píxel 20,2206)

Número total de píxeles: 251712

Valor	Número de píxeles	Área (m ²)
50	191637	65105527,90710786
255	60075	20409496,02122505

NDFI Serie

Cubeta 01

Anchura en píxeles: 1133 (unidades por píxel 16,8257)

Altura en píxeles: 689 (unidades por píxel 20,1933)

Número total de píxeles: 780637

Valor	Número de píxeles	Área (m ²)
0	667154	
50	223964	76072148,8927629
255	137348	46651950,78728366

Cubeta 02

Anchura en píxeles: 608 (unidades por píxel 16,8014)

Altura en píxeles: 414 (unidades por píxel 20,2206)

Número total de píxeles: 251712

Valor	Número de píxeles	Área (m ²)
50	202393	68759702,5089272
255	49319	16755321,41940571

Cociente GRD

Cubeta 01

Anchura en píxeles: 1133 (unidades por píxel 16,8257)

Altura en píxeles: 689 (unidades por píxel 20,1933)

Número total de píxeles: 780637

Valor	Número de píxeles	Área (m ²)
0	662326	
50	217582	73904423,48049301
255	143730	48819676,19955355

Cubeta 02

Anchura en píxeles: 608 (unidades por píxel 16,8014)

Altura en píxeles: 414 (unidades por píxel 20,2206)

Número total de píxeles: 251712

Valor	Número de píxeles	Área (m ²)
50	196739	66838848,7344119
255	54973	18676175,19392101

Cociente SLC

Cubeta 01

Anchura en píxeles: 1611 (unidades por píxel 11,8291)

Altura en píxeles: 979 (unidades por píxel 14,2073)

Número total de píxeles: 1577169

Número de píxeles SINDATOS: 846961

Valor	Número de píxeles	Área (m ²)
50	292512	49159438,37041806
255	437696	73558997,70600352

Cubeta 02

Anchura en píxeles: 863 (unidades por píxel 11,8196)

Altura en píxeles: 589 (unidades por píxel 14,2209)

Número total de píxeles: 508307

Valor	Número de píxeles	Área (m ²)
50	355702	59788360,33498471
255	152605	25650692,79599311

H - Alfa

Cubeta 01

Anchura en píxeles: 1611 (unidades por píxel 11,8291)

Altura en píxeles: 979 (unidades por píxel 14,2073)

Número total de píxeles: 1577169

Número de píxeles SINDATOS: 846962

Valor	Número de píxeles	Área (m ²)
50	464389	78045011,57354635
255	265818	44673256,44332003

Cubeta 02

Anchura en píxeles: 863 (unidades por píxel 11,8196)

Altura en píxeles: 589 (unidades por píxel 14,2209)

Número total de píxeles: 508307

Valor	Número de píxeles	Área (m ²)
50	422230	70970754,6885893
255	86077	14468298,44238851

H - Alfa Clasif

Cubeta 01

Anchura en píxeles: 1611 (unidades por píxel 11,8291)

Altura en píxeles: 979 (unidades por píxel 14,2073)

Número total de píxeles: 1577169

Número de píxeles SINDATOS: 846915

Valor	Número de píxeles	Área (m ²)
50	347633	58423049,13763018
255	382621	64303117,03460027

Cubeta 02

Anchura en píxeles: 863 (unidades por píxel 11,8196)

Altura en píxeles: 589 (unidades por píxel 14,2209)

Número total de píxeles: 508307

Valor	Número de píxeles	Área (m ²)
50	366807	61654950,18131677
255	141500	23784102,94966105

ANEXO III. Matrices de Error de los Métodos utilizados

NDWI

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	17222,0
3	255	50	7318,0
4	255	255	28409,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	17222	7318	24540
255	0	28409	28409
Total	17222	35727	52949

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,5320	0,2261	849655979,0885	0,7581
255	0,0000	0,2419	271176269,0228	0,2419
Total	0,5320	0,4680	1120832248,1113	
Area	596282611	524549637	1120832248	
SE	0,0022	0,0022		
SE area	2481293	2481293		
95% CI area	4863335	4863335		
PA [%]	100,0000	51,6970		
UA [%]	70,1793	100,0000		

Precisión total [%] = **77,3942**

Clasificación Kappa = **0,5324**

Unidad de Área = metro²

SE = Error Estandar

CI = Intervalo de confianza

PA = Exactitud del Productor

UA = Exactitud del Usuario

Mixto

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	17505.0
2	50	255	593.0
3	255	50	4421.0
4	255	255	32921.0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	17505	4421	21926
255	593	32921	33514
Total	18098	37342	55440

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0.6447	0.1628	953620707.9033	0.8076
255	0.0034	0.1890	227245751.2689	0.1924
Total	0.6481	0.3519	1180866459.1722	
Área	765360437	415506023	1180866459	

SE 0.0022 0.0022

SE área 2589149 2589149

95% CI área 5074732 5074732

PA [%]99.4746 53.7236

UA [%] 79.8367 98.2306

Precisión total [%] = **83.3764**

Clasificación Kappa = **0.5934**

Umbral Manual

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	16928,0
2	50	255	295,0
3	255	50	6077,0
4	255	255	29647,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	16928	6077	23005
255	295	29647	29942
Total	17223	35724	52947

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,6209	0,2229	997193436,7762	0,8439
255	0,0015	0,1546	184510049,4175	0,1561
Total	0,6225	0,3775	1181703486,1937	
Area	735592717	446110770	1181703486	
SE	0,0025	0,0025		
SE area	2900610	2900610		
95% CI area	5685196	5685196		
PA [%]	99,7529	40,9522		
UA [%]	73,5840	99,0148		

Precisión total [%] =**77,5547**

Clasificación Kappa =**0,4601**

NDFI

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	16665,0
2	50	255	558,0
3	255	50	9432,0
4	255	255	26296,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	16665	9432	26097
255	558	26296	26854
Total	17223	35728	52951

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,5344	0,3024	988873743,4738	0,8368
255	0,0034	0,1598	192853516,0816	0,1632
Total	0,5378	0,4622	1181727259,5554	
Area	635481460	546245799	1181727259	
SE	0,0025	0,0025		
SE area	2945604	2945604		
95% CI area	5773383	5773383		
PA [%]	99,3694	34,5717		
UA [%]	63,8579	97,9221		

Precisión total [%] =**69,4171**

Clasificación Kappa =**0,3556**

NDFI Serie

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	16249,0
2	50	255	974,0
3	255	50	14431,0
4	255	255	21297,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	16249	14431	30680
255	974	21297	22271
Total	17223	35728	52951

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,4652	0,4132	1037987907,1725	0,8784
255	0,0053	0,1163	143739352,3829	0,1216
Total	0,4705	0,5295	1181727259,5554	
Area	556034195	625693064	1181727259	
SE	0,0025	0,0025		
SE area	2964413	2964413		
95% CI area	5810250	5810250		
PA [%]	98,8694	21,9681		
UA [%]	52,9628	95,6266		

Precisión total [%] =**58,1522**

Clasificación Kappa =**0,1988**

Cociente GRD

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	17125,0
2	50	255	98,0
3	255	50	14376,0
4	255	255	21352,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	17125	14376	31501
255	98	21352	21450
Total	17223	35728	52951

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,4932	0,4140	1072069629,8518	0,9072
255	0,0004	0,0924	109639285,4088	0,0928
Total	0,4936	0,5064	1181708915,2607	
Area	583313919	598394996	1181708915	
SE	0,0025	0,0025		
SE area	3009115	3009115		
95% CI area	5897866	5897866		
PA [%]	99,9141	18,2385		
UA [%]	54,3634	99,5431		

Precisión total [%] =**58,5551**

Clasificación Kappa =**0,1796**

Cociente SLC

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	34527,0
2	50	255	384,0
3	255	50	21974,0
4	255	255	50056,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	34527	21974	56501
255	384	50056	50440
Total	34911	72030	106941

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,5316	0,3383	1027830600,2982	0,8699
255	0,0010	0,1291	153725593,7164	0,1301
Total	0,5326	0,4674	1181556194,0146	
Area	629263748	552292446	1181556194	
SE	0,0018	0,0018		
SE area	2108862	2108862		
95% CI area	4133369	4133369		
PA [%]	99,8140	27,6222		
UA [%]	61,1087	99,2387		

Precisión total [%] =**66,0695**

Clasificación Kappa =**0,2870**

H - Alfa

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	33218,0
2	50	255	1693,0
3	255	50	35256,0
4	255	255	36776,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	33218	35256	68474
255	1693	36776	38469
Total	34911	72032	106943

> AREA BASED ERROR MATRIX

> Referencia

V_Classified	50	255	Area	Wi
50	0,4272	0,4534	1040389521,0688	0,8805
255	0,0053	0,1142	141133058,5086	0,1195
Total	0,4324	0,5676	1181522579,5774	
Area	510923331	670599249	1181522579	
SE	0,0017	0,0017		
SE area	1992547	1992547		
95% CI area	3905393	3905393		
PA [%]	98,7843	20,1196		
UA [%]	48,5118	95,5991		

Precisión total [%] =**54,1364**

Clasificación Kappa =**0,1683**

H - Alfa Clasif

ErrMatrixCode	Referencia	Classified	PixelSum
1	50	50	34066,0
2	50	255	800,0
3	255	50	15139,0
4	255	255	56971,0

> ERROR MATRIX (pixel count)

> Referencia

V_Classified	50	255	Total
50	34066	15139	49205
255	800	56971	57771
Total	34866	72110	106976

> AREA BASED ERROR MATRIX

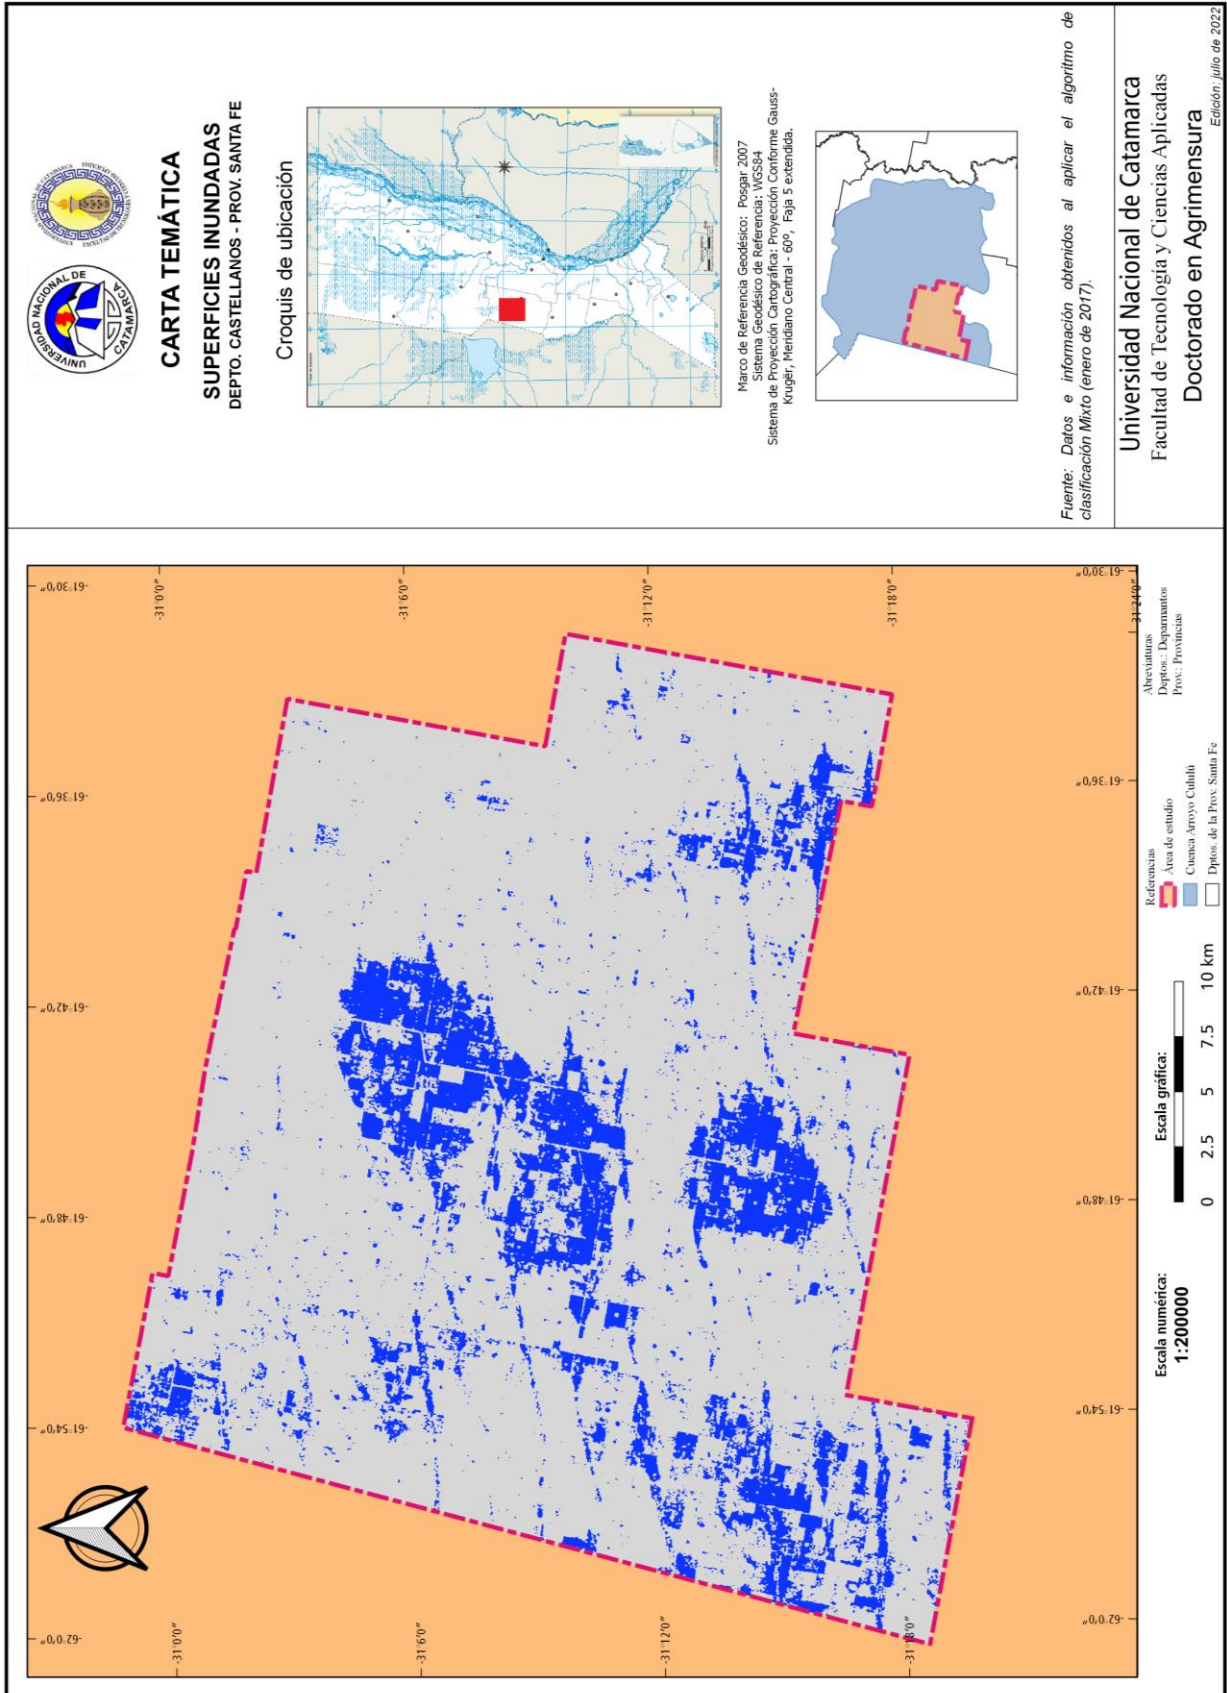
> Referencia

V_Classified	50	255	Area	Wi
50	0,5982	0,2658	1020939480,9828	0,8640
255	0,0019	0,1341	160716702,6339	0,1360
Total	0,6000	0,4000	1181656183,6167	
Area	709050574	472605610	1181656183	
SE	0,0018	0,0018		
SE area	2125658	2125658		
95% CI area	4166289	4166289		
PA [%]	99,6861	33,5356		
UA [%]	69,2328	98,6152		

Precisión total [%] =**73,2291**

Clasificación Kappa =**0,3733**


ANEXO IV. Cartografías temáticas de las superficies inundadas






CARTA TEMÁTICA
SUPERFICIES INUNDADAS
 DEPTO. CASTELLANOS - PROV. SANTA FE

Croquis de ubicación



Marco de Referencia Geodésico: Pogar 2007
 Sistema Geodésico de Referencia: WGS84
 Sistema de Proyección Cartográfica: Proyección Conforme Gauss-Kruger, Meridiano Central - 60°, Faja 5 extendida.



Fuente: Datos e información obtenidos al aplicar el algoritmo de clasificación Mixto (enero de 2017).

Universidad Nacional de Catamarca
 Facultad de Tecnología y Ciencias Aplicadas
 Doctorado en Agrimensura
 Edición: julio de 2022

