

Clasificación de áreas sembradas y determinación del momento de cosecha en Caña de azúcar y Pastizales mediante imágenes ópticas y SAR

Por *Ignacio Gastón Pascual*

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

MAGISTER EN APLICACIONES DE INFORMACIÓN ESPACIAL

UNIVERSIDAD NACIONAL DE CÓRDOBA

Junio, 2018

©IG - CONAE/UNC 2018

©FaMAF - UNC 2018

Director: Mgter. Lic. Rodrigo Edrosa

Co-Director: Ing. Esp. Alvaro Soldano

Asesor Metodológico: Dr. Marc Thibeault



Esta obra está bajo una [Licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/).

*¿Qué es la vida? Un frenesí.
¿Qué es la vida? Una ilusión,
una sombra, una ficción,
y el mayor bien es pequeño:
que toda la vida es sueño,
y los sueños, sueños son.*

Soliloquio de Segismundo
Pedro Calderón de la Barca

Resumen

La interpretación fenológica y la clasificación de cultivos a partir de sensores remotos surgen como las aplicaciones más utilizadas y necesarias de cara al asesoramiento agronómico a partir de técnicas espaciales. El desarrollo de esta tesis tiene como finalidad explorar el comportamiento de las imágenes SAR y ópticas en diferentes cultivos, tales como el cultivo de la caña de azúcar y los pastizales naturales, obtener el área sembrada con caña de azúcar y realizar mapas de momentos fenológicos de interés. Esta situación se contempla en diferentes zonas de estudio: la región central de la Provincia de Tucumán para el cultivo de la caña de azúcar y la región norte de Italia para el análisis de los pastizales naturales. Los sensores satelitales utilizados son: Landsat 8 como exponente de imágenes ópticas, Cosmo SkyMed en polarización HH y Sentinel 1 polarización HV como exponentes de imágenes SAR. Se realizó de manera exploratoria una comparación de datos ópticos y datos SAR. Se utilizó un conjunto de imágenes SAR, para evaluar clasificadores supervisados y no supervisados. Finalmente se realizaron mapas a partir del algoritmo de árbol de decisión para determinar momentos fenológicos particulares como lo es la cosecha en caña de azúcar y el inicio de crecimiento en pastizales naturales. Es necesario abordar con mayor profundidad la comparación de datos ópticos y SAR y seleccionar polarizaciones contrastantes para su evaluación. La clasificación SAR fue adecuada con los clasificadores no supervisados y baja con el clasificador supervisado evaluado. Los mapas que se obtuvieron mediante el uso del algoritmo de árbol de decisión, permitieron analizar eventos puntuales de manera óptima en grandes superficies.

Abstract

The phenological interpretation and the classification crops from remote sensors they arise as the most used and necessary applications with a view to the agronomic advice from spatial technologies. The development of this thesis has as purpose explore the behavior of the images SAR and optical in different crops, such as the crop of the sugar cane and the meadows, to obtain the area sowed with sugar cane and to realize maps of moments phenological of interest. This situation contemplates different zones of study the central region of Tucumán Province for the crop of the sugar cane and the north region of Italy for the analysis of the meadows. The satellite sensors used are Landsat 8 as exponent of optical images, Cosmo SkyMed in polarization HH and Sentinel 1 polarization HV as exponents of images SAR. There was realized in an exploratory way a comparison of optical information and information SAR. A set of images SAR was in use for evaluating supervised and not supervised classifiers. Finally maps were realized from the algorithm of tree of decision to determine particular phenological moment, such as harvest in the crop in sugar cane and the beginning of growth in natural pastures. It is necessary to approach with major depth the comparison of optical information and SAR and to select polarizations contrasting for his evaluation. The SAR classification was adequate with the unsupervised classifiers and low with the supervised classifier evaluated. The maps that were obtained by using the decision tree algorithm, allowed to analyze specific events optimally in large areas.

Palabras Clave

Caña de azúcar – Pastizales Naturales – Teledetección – Imágenes Ópticas –
Imágenes SAR

Agradecimientos

En el camino todo se resume en los afectos, el pasado, el presente y el futuro, fueron germen de fraternidad, amistad y amor, en todos los casos concluye sobre el mismo punto, en lo importante, lo que trasciende, lo que dejamos. Este trabajo fue posible gracias al aporte del estado nacional, en el contexto académico del Instituto Gulich de la CONAE y al entorno personal que me ayudo incondicionalmente. Urge agradecer al equipo de ciencia de la misión SAOCOM, Laura, Alvaro y Rodrigo. A Claudia Notarnicola y al EURAC por la estadía de investigación en Bolzano, Italia. A mis padres Nestor y Norma por dejar que brote en mí, el sentido de la libertad, a mis hermanos Fede, Clari y Esteban por enseñarme a compartir, a mis amigos y hermanos de la vida Fer, Manu, Guille y Fer por la gratitud y la necesidad de encontrarnos día a día, como así también a los nuevos amigos forjados en la MAIE, de todos y cada uno de ellos guardo con orgullo el haberlos conocido y compartido estos dos años juntos. A Ailin por su amor incondicional y a Emilia, por cambiarme la vida.

Contenido

Resumen	IV
Abstract.....	V
Palabras Clave	VI
Agradecimientos	VII
Índice de ilustraciones	XI
Índice de Tablas	XIV
Listado de Acrónimos	XV
Capítulo Uno	1
Introducción	1
1.1 Caña de azúcar.....	3
1.2 Pastizales Naturales.....	7
Objetivos de la Tesis.....	8
Capitulo Dos.....	9
Área de Estudio	9
2.1 Noroeste Argentino	9
2.2 Norte de Italia.....	12
Capitulo Tres	14
Marco Teórico.....	14
3.1 Características de la vegetación en la teledetección espacial	16
3.2 Radar de Apertura Sintética	18
Capitulo Cuatro	23
Materiales y Métodos.....	23
4.1 Imágenes Cosmo SkyMed	24
4.2 Imágenes Sentinel 1.....	26
4.3 Imágenes Landsat 8.....	28
4.4 Datos de Campo	30

4.5 Pre-procesamiento de imágenes.....	33
4.6 Procesamiento de imágenes	43
Capitulo Cinco	59
Resultados.....	59
5.1 Comparación de datos ópticos y SAR.....	59
5.2 Clasificaciones	66
Capitulo Seis	82
Conclusiones	82
Anexo	85
Anexo 1: Tablas de datos de campo de la zona de estudio secundaria, en Bolzano, Italia.....	85
Anexo 2: Scripts en R-studio.....	96
Anexo 3: Tablas de valores medios en la respuesta SAR y óptica sobre ROI de caña de azúcar	97
Anexo 4: Clasificaciones de la zona de estudio principal	98
Anexo 5: Tabla de errores de Confusión y Omisión en las clasificaciones SAR.....	99
Anexo 6: Mapa de Cosecha de caña de azúcar 2016.....	100
Anexo 7: Vector de datos de campo y puntos aleatorios generados y Matriz de confusión obtenida a partir de los ROI de puntos aleatorios	101
Anexo 8: Mapa de Corte en Pastizales Naturales, DOMEF 1500, en la Provincia de Bolzano, Italia	102
Anexo 9: Mapa de Inicio de crecimiento en Pastizales Naturales, DOMEF 1500, en la Provincia de Bolzano, Italia	103
Referencias	105

Índice de ilustraciones

Ilustración 1: Regiones Fitogeográficas Argentinas (PlanEAR, 2017)	4
Ilustración 2: Evolución Fenológica de la caña de azúcar (FAO, 2017)	5
Ilustración 3: Área de Estudio en la República Argentina	10
Ilustración 4: Área de estudio secundaria en la República Italiana	13
Ilustración 5: Espectro Electromagnético (Pérez Gutiérrez & Muñoz Nieto, 2006)	15
Ilustración 6: Transmisividad atmosférica (Lillesand, Kiefer, & Chipman, 2008).....	16
Ilustración 7: Firma espectral de la vegetación vigorosa (Chuvieco Salinero, 2006) ...	17
Ilustración 8: Geometría de adquisición SAR (Memarsadegh & Rincon, 2013).....	19
Ilustración 9: Distorsiones geométricas de una imagen SAR (European Space Agency, 2012).....	20
Ilustración 10: Representación vectorial del Speckle	21
Ilustración 11: Interacción con la vegetación (CCRS, 2005)	22
Ilustración 12: Diagrama de la metodología utilizada en el trabajo de tesis	23
Ilustración 13: Modos operativos de la constelación Cosmo Skymed (Italian Space Agency, 2009)	24
Ilustración 14: Los 5 tipos de productos estándar en COSMO-SkyMed (Italian Space Agency, 2009)	25
Ilustración 15: Modos operativos de la constelación Sentinel 1 (European Space Agency, 2013)	27
Ilustración 16: Bandas espectrales del Landsat 8 (OLI y TIRS) y Landsat 7 (Department of the Interior U.S. Geological Survey, 2016)	29
Ilustración 17: Verdad de campo, del área de estudio principal	31
Ilustración 18: Valores promedio NDVI y dB en la estación VIMES 1500	32
Ilustración 19: Valores promedio NDVI y dB en la estación DOMEF 1500.....	32
Ilustración 20: Adquisición de la Phenocam, en estación Vimes 1500.....	33
Ilustración 21: Ventana de calibración radiométrica y fracción de imagen CSK calibrada	34
Ilustración 22: Ventana de multilooking, en SNAP	35
Ilustración 23: Antes y después de aplicar multilook en una imagen CSK, visualización en Potencia (SNAP)	36
Ilustración 24: Ventana de filtrado speckle, en SNAP	37

Ilustración 25: Antes y después de aplicar filtro Gamma Map en una imagen CSK, visualización en Potencia (SNAP).....	38
Ilustración 26: Ventana de corrección terrena, en SNAP y fracción de imagen CSK corregida.....	39
Ilustración 27: Grafo de procesamiento para imágenes CSK, en SNAP	39
Ilustración 28: Grafo de procesamiento para imágenes Sentinel 1, en SNAP	40
Ilustración 29: Ventana de corrección orbital, en SNAP	41
Ilustración 30: Ventana de eliminación de ruido térmico, en SNAP	42
Ilustración 31: Ejemplo de valor del valor decimal de pixel en BQA, de Landsat 8	46
Ilustración 32: Captura de Google Earth, correspondiente al lote homogéneo de una ROI de caña de azúcar	47
Ilustración 33: Captura de Google Street View, correspondiente al lote de caña de azúcar de la ilustración 32	48
Ilustración 34: ROI de caña de azúcar en imagen CSK a la izquierda y en NDVI derivado de Landsat 8 a la derecha.....	49
Ilustración 35: Esquema de jerarquía del Árbol de decisión	50
Ilustración 36: Comportamiento fenológico de una ROI de caña de azúcar.....	51
Ilustración 37: Espectro de referencia y espectro de prueba (Kruse et al., 1993).....	53
Ilustración 38: Firmas Temporales de diferentes usos de suelo	53
Ilustración 39: Resultados del análisis de separabilidad de ROI.....	54
Ilustración 40: Síntesis metodológica del algoritmo ISODATA, elaborado por (Edrosa, 2011).....	56
Ilustración 41: Patrones de agrupamiento en algoritmo K-means.....	57
Ilustración 42: Valores en dB, obtenidas sobre el conjunto de imágenes CSK polarización HH, en muestras de caña de azúcar,.....	60
Ilustración 43: Valores en NDVI obtenidos en sobre el conjunto de imágenes Landsat 8, en muestras de caña de azúcar	61
Ilustración 44: Comparación de los valores medios del conjunto de muestras de los datos SAR y datos ópticos.....	63
Ilustración 45: Valores en dB de muestras caña de azúcar contrapuesto con las precipitaciones de la EE INTA Famailla	65
Ilustración 46: Precisión general de las clasificaciones realizadas.....	67
Ilustración 47: Valores del índice Kappa para cada clasificador evaluado.....	67

Ilustración 48: Área Clasificada y error de comisión de la clasificación en caña de azúcar	68
Ilustración 49: Caída del NDVI en diferentes fechas	70
Ilustración 50: Procedimiento para realizar el mapa de cosecha de caña de azúcar	71
Ilustración 51: Mapa de Cosecha en caña de azúcar realizado con árbol de decisión...	72
Ilustración 52: Caída de dB en asociado al corte de pastizales	74
Ilustración 53: Procedimiento para realizar el mapa de corte en Pastizales naturales...	75
Ilustración 54: Mapa de fechas de corte en pastizales naturales, en zona cercana a la estación VIMES 1500.....	76
Ilustración 55: Registro a campo en las fechas que satelitalmente se detecta el corte ..	77
Ilustración 56: Procedimiento para realizar el mapa de inicio de crecimiento en pastizales naturales.....	78
Ilustración 57: Inicio de crecimiento en función de la temperatura de suelo y NDVI, extraído de (Notarnicola et al., 2017)	79
Ilustración 58: Mapa de fechas de inicio de crecimiento en pastizales naturales, en zona cercana a la estación VIMES 1500.....	80
Ilustración 59: Registro a campo en las fechas que satelitalmente se detecta el inicio de crecimiento	81

Índice de Tablas

Tabla 1: Modos operativos de la constelación Cosmo Skymed (Italian Space Agency, 2009).....	24
Tabla 2: Características de las Imágenes Cosmo SkyMed utilizadas	26
Tabla 3: Características de las Imágenes Sentinel 1 utilizadas	28
Tabla 4: Características de las Imágenes Landsat 8 utilizadas	30
Tabla 5: Clasificación de los valores de NDVI, elaborado por (Lopez Perez, Martinez Menes, & Fernandes Reynoso, 2015)	45
Tabla 6: Coeficientes aplicados a las firmas temporales en dB	55
Tabla 7: Parámetros ajustados para ISODATA.....	57
Tabla 8: Parámetros ajustados para K-means	58
Tabla 9: Porcentajes de exactitud de usuario y productor.....	68

Listado de Acrónimos

ASI	Agencia Spaziale Italiana
CONAE	Comisión Nacional de Actividades Espaciales
CSK	Cosmo SkyMed
EEAOC	Estación Experimental Agroindustrial Obispo Colombres
EURAC	European Academy of Bolzano
FAO	Organización de las Naciones Unidas para la Alimentación y la Agricultura
GRD	Ground Range Detected
INDEC	Instituto Nacional de Estadística y Censos
INTA	Instituto Nacional de Tecnología Agropecuaria
LaSRC	Landsat 8 Surface Reflectance Code
NDVI	Normalized Difference Vegetation Index
OLI	Landsat 8 Operational Land Imager
ROI	Region of Interest
SAOCOM	Satélite Argentino de Observación Con Microondas
SAM	Spectral Angle Mapper
SAR	Synthetic Aperture Radar
SLC	Single-look Complex Slant product
TIRS	Landsat 8 Thermal Infrared Sensor

Capítulo Uno

Introducción

El proceso de estimación de superficies ocupadas por diferentes cultivos adquiere importancia a diferentes escalas. La necesidad urgente de información precisa sobre la cobertura de la tierra en el contexto dinámico de cambio global ha sido expresada por muchas fracciones de la comunidad científica (Craig Dobson, Pierce, & Ulaby, 1996). El conocimiento de los diferentes usos de la tierra, tanto en su escala tanto espacial como temporal, son de importancia para el productor agropecuario que puede definir diferentes estrategias de manejo agronómico, y también para el estado permitiéndole llevar a cabo el seguimiento de las superficies implantadas para el control fiscal o para mejorar la asignación de recursos (Paruelo, Guerschman, Baldi, & Di Bella, 2004).

El sensado remoto en la agricultura tiene como uno de sus objetivos el manejo y la optimización de los recursos. En este contexto las aplicaciones de identificación de cultivos y superficies cultivadas son las más habituales (Riedel & Eckardt, 2013). Por esta razón las imágenes satelitales que trabajan en la región del espectro electromagnético óptico, como así también las de la región de las microondas, tienen la facultad de obtener de manera indirecta características de los diversos cultivos agrícolas. Las propiedades espectrales de la vegetación permiten percibir diferentes características en función de la longitud de onda con la que interactúan.

Se define a la clasificación como una representación abstracta de la situación a campo, aplicando criterios diagnósticos definidos o clasificadores (INTA, 2009). Uno de los procesos de clasificación más difundido es el abocado a los diferentes usos de la tierra (Guerschman, 2005). En referencia, es elemental precisar

adecuadamente el concepto de cobertura y el de uso de la tierra. Cobertura se refiere a las características físicas superficiales de la tierra, mientras que, cuando mencionamos el “uso de la tierra”, se hace referencia a las “actividades que la gente desarrolla sobre determinado tipo de cobertura para producir, cambiarla o mantenerla” (INTA, 2009).

El proceso de clasificación exhibe la dificultad de separación entre dos tipos de usos de la tierra. Dependerá del índice de área foliar y valores espectrales similares (Guerschman, Paruelo, Di Bella, Giallorenzi, & Pacin, 2003) en imágenes ópticas y de disimilitudes geométricas o dieléctricas, en imágenes Radar de Apertura Sintética (SAR). El uso de un conjunto de imágenes que representen en el tiempo las variaciones en la respuesta espectral de las diferentes superficies, favorecerá el proceso de clasificación de dichas áreas de interés, adquiriendo mayor información y más completa que el análisis individual de imágenes satelitales.

Los sistemas SAR poseen la capacidad de operar en todas las condiciones meteorológicas, incluso penetrar las nubes y adquirir datos según su frecuencia de operación. Numerosos trabajos indican sobre la sensibilidad de los sistemas de microondas a los escenarios de cultivos y la información que estos pueden proporcionar (Lopez Sanchez & Ballester Berman, 2009). Particularmente, la sensibilidad del radar a la biomasa depende de la geometría de los elementos vegetales, mientras que la capacidad de discriminación mejora cuando la planta está bien desarrollada o cuando todo el ciclo del cultivo está cubierto por datos multitemporales (Ferrazzoli, Guerriero, & Schiavon, 1999).

De manera contrastante, las imágenes ópticas tienen como principal limitación el efecto de que sus longitudes de onda son absorbidas o reflejadas por las nubes, dando como resultado imágenes degradadas (Moran, Inoue, & Barnes, 1997). A pesar de esta restricción, las imágenes multiespectrales proporcionan datos precisos, detallados y que pueden ser la base para la generación de información valiosa para los agricultores (Moran et al., 1997), en particular la generación de índices espectrales, concretamente el Normalized Difference Vegetation Index (NDVI) (Rouse, Haas, & Deering, 1974), que puede ser

utilizado para evaluar indirectamente las condiciones fisiológicas de un cultivo o ser una “entrada” de modelos más complejos que evalúan la productividad.

Resulta útil comprender que cualquier trabajo o interpretación de las superficies agrícolas y de uso de la tierra, pueden ser abordadas desde diferentes escalas, espacialmente, temporalmente o radiométricamente, permitiendo la utilización de los productos de diferentes sensores, bajo este criterio adecuando el trabajo a la información disponible.

1.1 Caña de azúcar

La caña de azúcar (*Sacharum officinarum L.*) es una gramínea perenne que se cosecha en condiciones de cultivo extensivo, entre los 12 y 14 meses de iniciado su crecimiento vegetativo. Su cultivo en el país adquiere importancia por ser el precursor del “azúcar blanco” y numerosos productos azucarados como establece el Código Alimentario Argentino (A.N.M.A.T., 1971) y que forman parte de la Canasta Básica Alimentaria (INDEC, 2017).

La superficie cultivada a nivel mundial asciende a 27.12 millones de hectáreas, representando el continente Americano el 53.5% del área cultivada. El promedio mundial de producción es de 76.5 ton/ha, datos actualizados al año 2014 (FAO, 2014).

En Argentina, actualmente, cinco provincias cultivan la caña de azúcar: Salta, Jujuy, Tucumán, Santa Fe y Misiones; siendo Tucumán la principal productora concentrando el 63% de la producción nacional de azúcar (Romero, Digonzelli, & Scandaliaris, 2009). La producción de azúcar se encuentra concentrada en tres provincias, Tucumán, Salta y Jujuy reúnen el 99,5% del azúcar producida (Anino & Pizzo, 2016). En el año 2016 la producción de azúcar alcanzó los 2 millones de toneladas (entre azúcares blancos y crudos), teniendo como destino tanto el mercado interno como el externo (Ploper, Fadda, & Olea, 2009; Rios, Perez, & Felipe, 2017).

1.1.1 Características fenológicas del cultivo de la caña de azúcar

Las características climáticas de la región productora de caña de azúcar en Argentina, se caracteriza por presentar un ciclo Monzónico, con precipitaciones concentradas en la estación cálida que oscilan entre los 700-800 milímetros anuales, hasta zonas con 1200-1300 milímetros anuales, siendo el invierno la estación seca. La expansión territorial del cultivo encuentra ciertas restricciones asociadas a condiciones topográficas y de relieve; hacia el oeste y por la disminución de las precipitaciones hacia el este y el sur.

Como se observa en la ilustración 1, la superficie cultivada con caña de azúcar se circunscribe a la Región Fitogeográfica de las Yungas en el “Distrito de la Selva de Transición” sobre el borde oriental de la Región Fitogeográfica de las Yungas y a la Región Chaqueña en el “Distrito Chaqueño Occidental” sobre el este de Salta, el extremo oriental de Jujuy y el este de Tucumán (Cabrera, 1971).

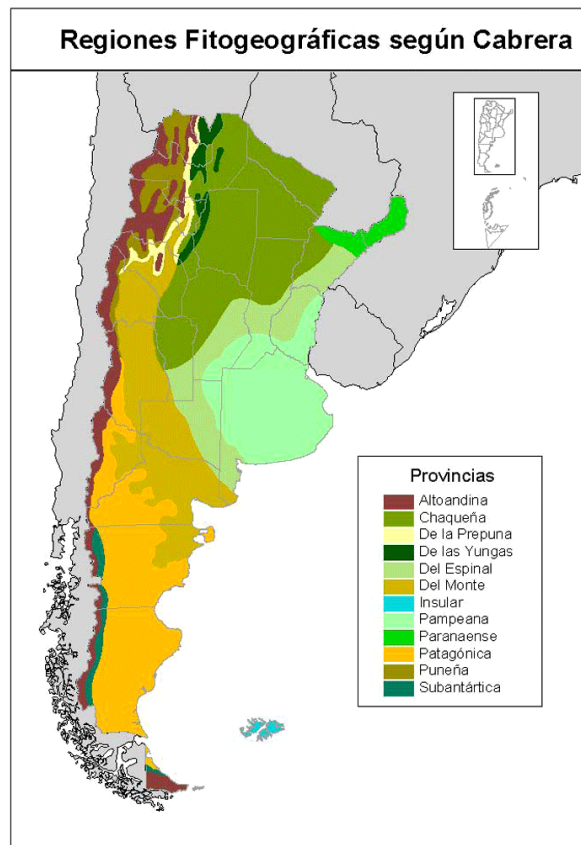


Ilustración 1: Regiones Fitogeográficas Argentinas (PlanEAR, 2017)

Como ya se mencionó, la caña de azúcar es una planta perenne, cuya renovación en plantaciones comerciales se produce alrededor de los cinco años de implantada. Crece formando matas constituidas por varios tallos macizos sin ramificar y con un sistema subterráneo formado por raíces y rizomas (Parodi, 1977).

Desde el punto de vista productivo el tallo es el órgano de interés comercial ya que en él se almacena el azúcar en aproximadamente un 12% cuando la caña alcanza la maduración. Los tallos están constituidos por alrededor de 20 a 25 entrenudos con diferentes características morfológicas (color, diámetro y longitud) según la variedad implantada (Soria, Federico José; Fandos, 1999).

La caña de azúcar se propaga asexualmente (propagación vegetativa) a partir de la brotación de las yemas que contiene el tallo. Se denomina “caña semilla” a la porción de tallo que se coloca en el surco al momento de la plantación. Normalmente un cañaveral bien establecido está constituido por unos 100.000 tallos de caña por hectárea, pudiendo descender esa cifra a 50.000 en cultivos pobres que han sufrido algún tipo de limitante y a medida que envejece el cañaveral. La ilustración 2, describe la fenología clásica del cultivo de la caña de azúcar, comprendida por el establecimiento (germinación y emergencia), el macollamiento y la elongación de los tallos, seguida por un rápido crecimiento y formación del rendimiento y finalmente la etapa de madurez del cultivo para la posterior cosecha.




Ilustración 2: Evolución Fenológica de la caña de azúcar (FAO, 2017)

La producción primaria de caña de azúcar es el eslabón crucial de la cadena de valor del azúcar y sus derivados. Cualquier proceso industrial subsiguiente obedece a un buen rendimiento productivo en términos de biomasa del cultivo.

La “zafra” o cosecha de la caña de azúcar, se realiza en el norte argentino, desde mediados de mayo a fines de octubre. Su duración depende de las condiciones climáticas imperantes, del proceso madurativo de la caña y de los volúmenes a procesar. La ausencia de lluvias, baja humedad relativa y temperaturas bajas y sin heladas, resultan las condiciones más adecuadas para un óptimo desarrollo de la zafra (Romero et al., 2009).

Productivamente el sector cañero argentino ha sufrido transformaciones en lo que respecta al manejo del cultivo a campo, beneficiado por la presencia de nuevas tecnologías, tanto de insumos como de procesos, que catalizaron dicha transformación. El mayor impacto está dado por el cambio de la cosecha manual y la quema de los cañaverales hacia la mecanización de la cosecha (Anino & Pizzo, 2016; Vicini & Vicini, 2010).

A pesar de la importancia económica de la actividad de la caña de azúcar en el norte del país, actualmente plantación, cosecha y transporte no presentan una planificación optimizada. Diferentes organismos públicos como INTA, EEAOC, y dentro de CONAE el grupo de aplicaciones de la misión SAOCOM, tienen como interés producir distintas aplicaciones, como las de identificar la diversidad de cultivos en la región Pampeana, y así también de regiones extra pampeanas donde adquieren relevancia otras actividades agropecuarias, como en este caso la caña de azúcar. Este estudio aporta información para la comprensión del comportamiento del cultivo de la caña de azúcar a través de la respuesta espectral de la señal del SAR y de las imágenes ópticas. En particular, intenta contribuir con información de mayor calidad, a partir de la generación de productos satelitales de mayor complejidad, como las clasificaciones espectrales de cultivos y los mapas de cosecha. Estos productos satelitales permiten un entendimiento global del cultivo a través de su monitoreo con sensores remotos y su aplicación en las denominadas técnicas de “agricultura de precisión o por ambientes”.

1.2 Pastizales Naturales

Los pastizales naturales son "comunidades vegetales" en las que distintas especies interactúan entre sí y con el ambiente en que se encuentran (De Leon, 2003). En la provincia de Bolzano, Italia, crecen sobre suelos poco profundos desarrollados sobre el material madre cercano a la superficie, los suelos son en general más húmedos debido al riego y a la presencia de mayor contenido orgánico (Bertoldi et al., 2015).

La agricultura de montaña es la principal fuente de ingresos para muchas familias de agricultores de la región del Sur del Tirol. Además de producir alimentos, los agricultores de montaña están cumpliendo la importante tarea de proteger la tierra (Peratoner, 2017). A su vez, en la región desempeñan un papel fundamental en el turismo local.

La composición de los pastizales naturales de la provincia del Bolzano, abundan especies tanto de dicotiledóneas como de monocotiledóneas, principalmente especies como *Alopecurus pratensis*, *Lolium perenne* y *Lolium multiflorum*, *Festuca pratensis*, *Arrhenatherum elatius*, *Trisetum flavescens*, y muchas especies de *Apiaciae* (*Anthriscus sylvestris*, *Heracleum sphondylium*, *Aegopodium podagraria*, *Taraxacum officinale*) (Peratoner, 2015).

Finalmente, esta combinación de especies, componen un hábitat particular que generan fuentes de trabajo en los agricultores zonales y que son un importante pilar en la conservación de especies de la región.

El aporte de este trabajo fue el desarrollo de mapas para determinar los momentos de corte e inicio de crecimiento de los pastizales naturales, a través de información SAR, que nos permite con limitaciones en función de la topografía del paisaje un conocimiento más exacto de la fenología de diversos cultivos de interés (Notarnicola et al., 2017).

Objetivos de la Tesis

- Clasificar, describir y caracterizar las superficies de la zona de estudio a través del uso combinado de imágenes SAR y óptica.
- Aplicar clasificaciones supervisadas (árboles de decisión, Spectral Angle Mapper) y no supervisadas (ISODATA, K-means) a imágenes, SAR y ópticas, en las áreas de estudio propuesto.
- Evaluar los diferentes clasificadores utilizados mediante el análisis de matrices de confusión.
- Estimar el momento de inicio de estación de crecimiento y momento de corte en pasturas en la región de la Provincia de Bolzano a través de procedimientos que incluyan clasificadores de árboles de decisión.
- Determinar a través de alguna metodología el periodo de cosecha para el cultivo de la caña de azúcar en el periodo de análisis.

Capítulo Dos

Área de Estudio

2.1 Noroeste Argentino

El área de estudio principal se encuentra en la región central del Norte de la República Argentina, área donde el cultivo de caña de azúcar adquiere más importancia, esencialmente sobre el territorio de la Provincia de Tucumán.

El área de estudio, como se expone en la ilustración 3, corresponde a una superficie circunscripta a la provincia de Tucumán, vecina a la Ciudad de San Miguel de Tucumán. Dicha extensión está integrada entre las localidades de Famailla hacia el sur, Bella Vista hacia el este y Lules hacia el Noroeste, delimitando una zona de aproximadamente 47 mil hectáreas, con una marcada dicotomía productiva, citrícola hacia el pedemonte y cañera hacia el este.

En el área cañera de Tucumán actualmente se cultivan alrededor de 217.000 ha, pero potencialmente tiene la capacidad de aumentar la superficie de cultivo alrededor de las 300.000 ha (Romero et al., 2009).

2.1.1 Características Climáticas

La región del noroeste del país, y la provincia de Tucumán en particular, presentan singularidades que permiten agruparlas dentro de un clima monzónico, caracterizado por la ocurrencia de la estación seca durante el invierno, y la mayor parte de las precipitaciones durante el verano.

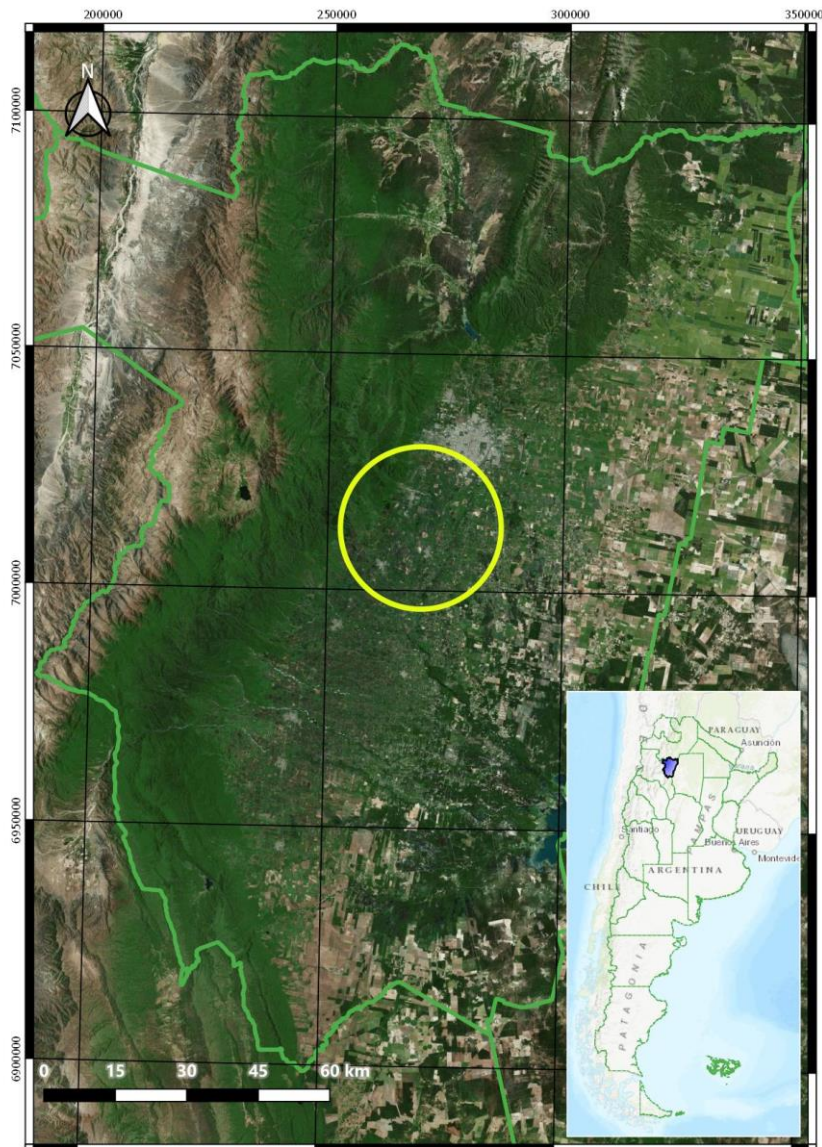


Ilustración 3: Área de Estudio en la República Argentina

Según (Zuccardi & Fadda, 1985) en el “Bosquejo agrológico de la Provincia de Tucumán”, definen al área de estudio de esta tesis como la región del pedemonte. La temperatura media anual de la región es de 19° C. La temperatura media del mes más cálido (enero) es de 25° C y la del mes más frío (julio) de 12° C. Es una región donde la ocurrencia de heladas es mínima y solo se pueden producir en forma excepcional (Zuccardi & Fadda, 1985). Este trabajo se centra sobre la subregión del “pedemonte húmedo y perhumedo” con un clima cálido con precipitaciones anuales superiores a los 1.000mm. La

evapotranspiración potencial es de 900mm aproximadamente, de tal manera que el balance hídrico es positivo.

2.1.2 Características Edáficas

En cuanto a las características del suelo en el área de estudio, se puede decir que la región está constituida por depósitos aluviales, texturas medias a gruesas y bien drenados (Romero et al., 2009). Las pendientes varían entre el 1 y 5% con una dirección general noroeste-sureste, perdiendo intensidad hacia el este al entrar en contacto con la llanura de sedimentación.

Los principales suelos de la región según la clasificación del “Soil Taxonomy” (USDA, 1999) abarcan los subgrupos de Hapludoles fluvénticos y cumúlicos, que constituyen los suelos dominantes del área y se originan en sedimentos aluviales y/o coluviales y por los Argiudoles típicos y Hapludoles taptoárgicos estos suelos se localizan sobre los materiales arcillo-limosos.(Zuccardi & Fadda, 1985).

Como resultado, las limitaciones del suelo en esta microrregión están dadas por la asociación entre factores topográficos y climáticos. Esta combinación aumenta el riesgo de la pérdida del suelo por erosión hídrica. Es recomendable en la escala de la parcela agrícola adoptar prácticas de mayor sustentabilidad por ejemplo la siembra y labranza en curvas de nivel, diseño de terrazas, etc.

2.1.3 Uso Actual

Las características anteriormente nombradas determinan que la aptitud productiva de la región está vinculada con actividades agrícolas y forestales. La principal actividad agrícola que se realiza sobre la región es el cultivo de la caña de azúcar y de los citrus hacia el oeste. Se realizan, asimismo, con éxito plantaciones de papa y hortalizas de primicia (Zuccardi & Fadda, 1985). Las

características climáticas, en resumen, por ser un área libre de heladas definen una zona óptima para el cultivo de frutales subtropicales, especialmente paltas y chirimoyas, actualmente en expansión (Zuccardi & Fadda, 1985).

2.2 Norte de Italia

El área de estudio secundaria tal como se presenta en la ilustración 4, corresponde a la región del Sur del Tirol situada en el norte de Italia, al límite con Austria. El Sur del Tirol tiene una superficie de 7.400 km² y una población total de 511.750 habitantes aproximadamente. Geográficamente el Sur del Tirol se encuentra en el centro de los Alpes y presenta un gradiente de altitud pronunciado que oscila desde 190 metros a los 3890 msnm y una compleja topografía. La región se caracteriza por un típico clima de montaña. Los cultivos más relevantes de esta zona son los pastizales naturales, en los que se centra nuestro trabajo, pasturas implantadas, huertos y viñedos (Notarnicola et al., 2017) que determinan la existencia de un sistema productivo variado en términos tecnológico y de proceso. Además, y no menos importante, alrededor del 44% o aproximadamente unos 3228 km² del Sur del Tirol está cubiertos por bosques (Notarnicola et al., 2017).

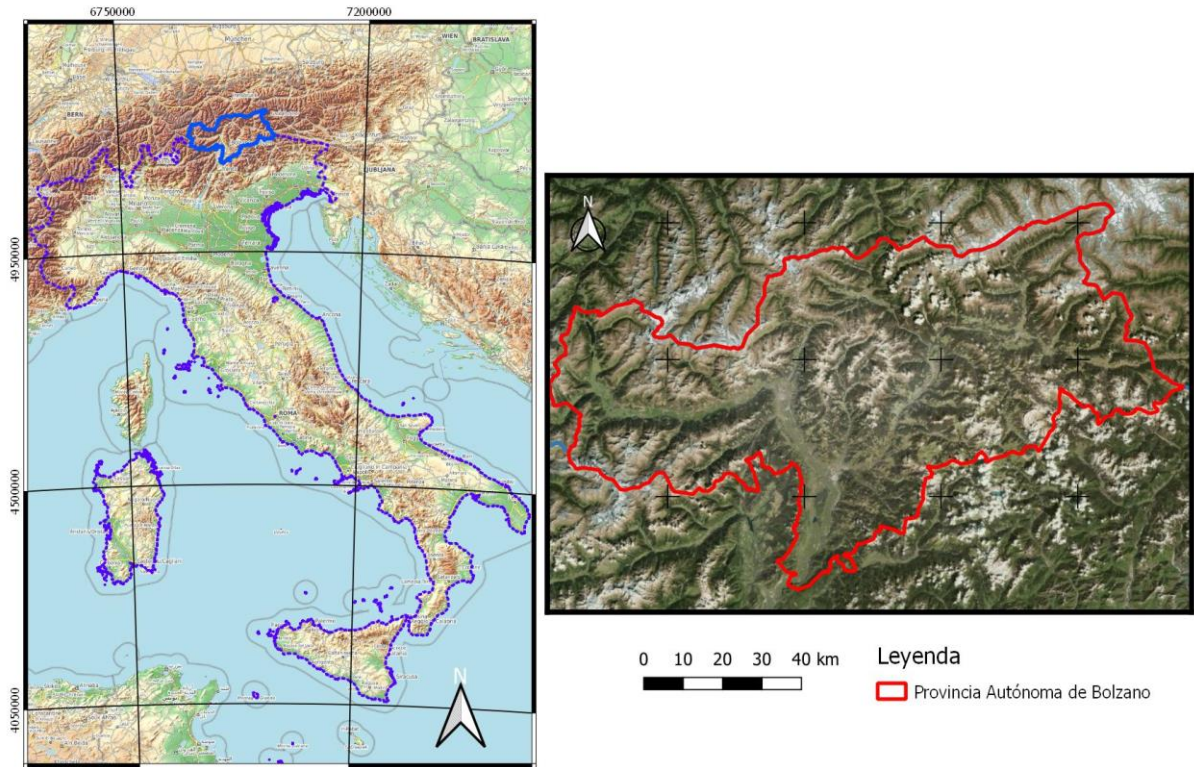


Ilustración 4: Área de estudio secundaria en la República Italiana

Capítulo Tres

Marco Teórico

La teledetección es una herramienta única y eficiente en términos de costo, que nos permite la adquisición de información temporalmente y espacialmente oportuna con la capacidad de una alta frecuencia de revisita (Riedel & Eckardt, 2013).

Se define a la teledetección espacial, como la técnica que permite adquirir imágenes de la superficie terrestre, desde sensores instalados sobre plataformas satelitales (Chuvienco Salinero, 2006).

La percepción remota es posible gracias a la interacción de un flujo energético con las cubiertas terrestres (Pérez Gutiérrez & Muñoz Nieto, 2006). La radiación electromagnética es el vehículo necesario que nos ayuda a describir cómo reaccionan los diferentes objetos de la superficie terrestre, durante eventos que la caracterizan, y de esta manera poder estudiarlos indirectamente.

El espectro electromagnético como se puede visualizar en la ilustración 5, en pocas palabras, es el registro que permite seleccionar los rangos espectrales con que observaremos indirectamente las problemáticas de estudio. Sin adentrarse en detalles físicos, en la actualidad la mayoría de los sensores, se diseñan para aprovechar la energía de la porción del espectro visible (entre 0.4 μm y 0.7 μm). También resultan de interés las regiones del infrarrojo cercano (entre 0.7 μm y 1.3 μm), en donde se pueden detectar masas vegetales y concentraciones de humedad; el infrarrojo medio (entre 1.3 μm y 8 μm); el infrarrojo lejano (entre 8 μm a 14 μm) porción emisiva del espectro (Chuvienco Salinero, 2006). Existe un grupo de sensores que captan información desde la porción del espectro que corresponde a las microondas (longitudes de onda

mayores a 1 mm) y brindan información contrastante y complementaria respecto a la obtenida del espectro óptico electromagnético.




Ilustración 5: Espectro Electromagnético (Pérez Gutiérrez & Muñoz Nieto, 2006)

Es adecuado manifestar que los componentes de un sistema de percepción remoto son: la fuente de energía, que se refiere al origen del flujo energético que detecta el sensor; las superficies a estudiar, en alusión a los diversos usos del suelo con los que interactúa la energía; el sistema sensor, compuesto por el sensor en sí mismo, la plataforma, el sistema de almacenamiento y envío de información a las estaciones en tierra; el sistema de recepción, que es el sitio en donde es recibida la información enviada por el sistema sensor y es organizada para su disposición; finalmente el analista, es la persona que interpreta la información y la convierte para que pueda ser interpretada por el usuario final, tal como menciona (Murillo Sandoval & Carbonell González, 2012).

Antes de avanzar, debemos inferir que entre la superficie terrestre que es objeto de estudio y el sensor que capta la fuente de energía, existe un medio muy heterogéneo como la atmósfera, que modifica cuantitativamente el flujo de energía que incide sobre dicha superficie (Murillo Sandoval & Carbonell González, 2012). De tal manera, podemos diferenciar la influencia de este medio a través del impacto en la transmisividad en las diferentes longitudes de onda del espectro electromagnético. Por enumerar los elementos que se encuentran en la atmósfera y afectan el flujo energético que alcanza la superficie terrestre se hallan, los gases, el vapor de agua y los aerosoles siendo responsables del

tipo y de la magnitud de las interacciones entre la atmósfera y la radiación (Murillo Sandoval & Carbonell González, 2012). Como corolario se definen a las ventanas atmosféricas, aquellas regiones del espectro electromagnético en donde la transmisividad en la atmósfera es lo suficientemente alta (Chuvieco Salinero, 2006), y es posible el uso de los sensores remotos con mínimas interferencias. En la ilustración 6, se observa la transmisividad de la atmósfera en función a las diferentes longitudes de onda del espectro electromagnético, en sintonía con lo descrito con respecto a las ventanas atmosféricas.




Ilustración 6: Transmisividad atmosférica (Lillesand, Kiefer, & Chipman, 2008)

3.1 Características de la vegetación en la teledetección espacial

La vegetación entendida como una compleja estructura física, es una de las superficies de mayor impacto en el estudio y generación de aplicaciones en la teledetección. La estimación de parámetros biofísicos de la vegetación tiene importancia en la caracterización del medio de manera directa, o en el estudio y percepción de un proceso dinámico mayor, en la que no interviene individualmente e.g Modelos de Simulación de Cultivos (Pérez Gutiérrez & Muñoz Nieto, 2006).

Cada objeto de la superficie de la tierra exhibe un patrón espectral característico (Murillo Sandoval & Carbonell González, 2012) que le permite diferenciarlo y distinguirlo cuando es analizado de manera transversal a través de la percepción

remota. La respuesta espectral de la vegetación se encuentra influenciada por el estado fenológico, la morfología de las plantas y el contenido de humedad de la vegetación (Chuvieco Salinero, 2006), y todo ello supeditado a la condición de vigorosidad de la estructura vegetal bajo análisis.

La firma espectral clásica de una estructura vegetal vigorosa, está definida por las siguientes peculiaridades, como en la ilustración 7 se contempla, existe una baja reflectividad en la región del espectro visible, allí se producen picos de absorción, particularmente en la zona del azul y el rojo, por la presencia de pigmentos fotosintéticos; en el infrarrojo cercano son característicos los altos valores de reflectancia, por la estructura celular interna de las hojas (Murillo Sandoval & Carbonell González, 2012), principalmente por el efecto del mesófilo esponjoso. Finalmente, en la región del infrarrojo medio, la vegetación suele presentar baja reflectividad determinada por el contenido de humedad (Kandus, 2016c).




Ilustración 7: Firma espectral de la vegetación vigorosa (Chuvieco Salinero, 2006)

Existen diversos fundamentos (Abdel-Rahman, Ahmed, & Van den Berg, 2010; Steven & Clarck, 1990; Zhao, Reddy, Gopal, & Reddy, 2005) que aseveran que la variabilidad espectral en la vegetación es dependiente del contenido de pigmentos en hoja, deficiencias de nitrógeno, presencia de plagas, y diversos parámetros agronómicos, precisando la complejidad del análisis de la misma.

3.2 Radar de Apertura Sintética

El SAR o Synthetic Aperture Radar, por su definición en inglés, es un sistema RADAR de iluminación lateral que produce una imagen de resolución fina de la superficie bajo observación (CCRS, 2005). Es un dispositivo que opera en el dominio de microondas que permite generar imágenes de alta resolución (Buemi, 2012).

El sistema SAR, posibilita y es muy preciso en la medición de distancias. La formación de imágenes SAR se obtiene a través del cálculo del tiempo entre el pulso que es emitido por el radar y el que regresa al sensor.

Como se observa en la ilustración 8, la geometría de adquisiciones SAR, está formada por la distancia entre el sensor radar y el objetivo en la superficie del terreno en la dirección perpendicular al vuelo, denominada rango (o alcance). El azimut, en cambio, es la distancia a lo largo de la trayectoria en la dirección de vuelo. En un sistema radar la resolución tiene dos dimensiones, una en la dirección del alcance y otra en la dirección del azimut.

El SAR es un tipo de sistema de teledetección activo, esto quiere decir que posee su propia fuente de energía para la iluminación del blanco y la adquisición de información. A su vez, las antenas SAR se configuran para recibir y transmitir radiación electromagnética polarizada horizontal o verticalmente (European Space Agency, UNESCO, & SARMAP, 2009). Cuando la energía transmitida es polarizada en la misma dirección en la que es recibida, al sistema se le conoce como de polarización similar (CCRS, 2005), e.g HH o VV. En cambio cuando la energía transmitida se polariza en una dirección ortogonal a la recibida, al sistema se le conoce como de polarización cruzada (CCRS, 2005), e.g HV o VH.

Este tipo de sistemas presentan como ventaja sobre los sensores ópticos la posibilidad de operar durante el día y la noche y la de penetrar con algunas limitaciones, dependiendo de la frecuencia de operación o longitud de onda, las diferentes capas de nubes.




Ilustración 8: Geometría de adquisición SAR (Memarsadegh & Rincon, 2013)

La posición relativa de los objetos de la superficie, determinada por el modo de observación lateral de los sensores SAR, ocasionan distorsiones geométricas en las imágenes. Tres son las principales distorsiones que hallamos en las imágenes SAR: Layover, Foreshortening y Shadows. El layover o inversión por relieve ocurre cuando la energía reflejada de la porción superior de un objeto se recibe antes que la que proviene de la porción inferior, de tal manera que la parte superior del objeto se verá desplazada de su base (CCRS, 2005). Foreshortening o acortamiento frontal es un caso en que los puntos elevados del terreno aparecen desplazados hacia el sensor, debido a que las distancias en la dirección del pulso son menores que las de los puntos bajos del terreno (Ruiz Fernández, 2013). Shadows o sombreado, se refiere por la propia definición a las zonas de la imagen de la que no hay retorno de la señal, por lo que hay pérdida completa de información. En la ilustración 9 se describen gráficamente los tres principales tipos de distorsiones geométricas en las imágenes SAR.

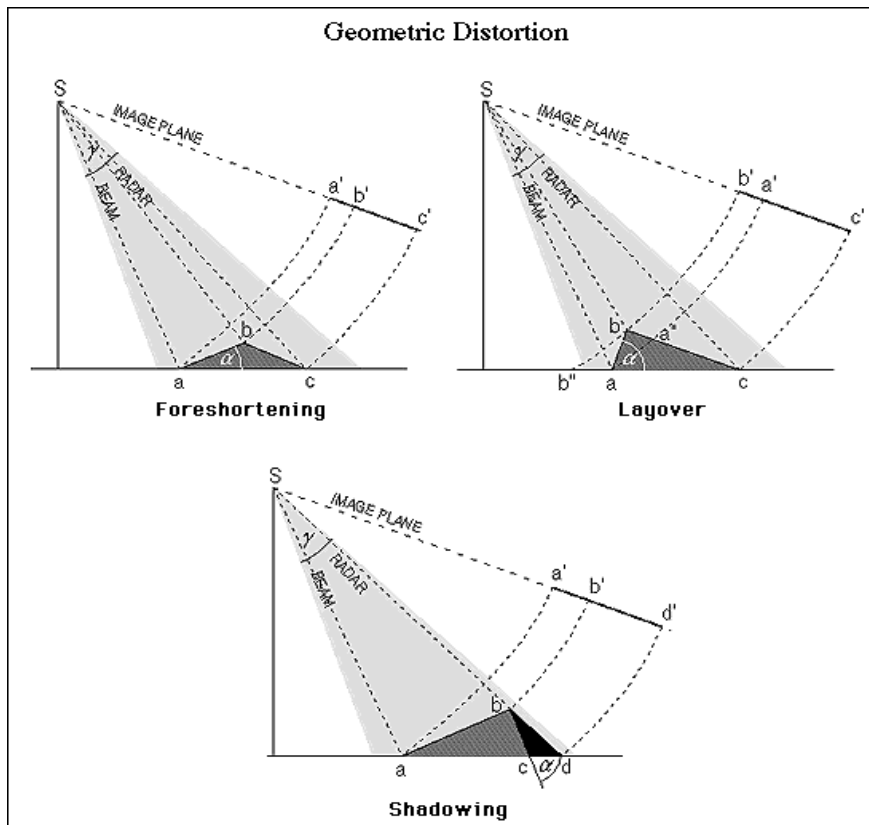


Ilustración 9: Distorsiones geométricas de una imagen SAR (European Space Agency, 2012)

Otra tipo de distorsión clásica en las imágenes SAR, que afecta a la radiometría de la imagen, es el “Speckle” o Moteado, que se refiere a la interferencia coherente de las ondas reflejadas difusamente por los elementos del terreno (CCRS, 2005). Las ondas generadas por un sistema de observación SAR son de naturaleza coherente (diferencia de fase constante), por lo que el fenómeno del Speckle puede ser definido como un ruido de naturaleza aleatoria de los elementos de imagen. Si la diferencia de fase generada por la superficie reflectora se acumula, es un fenómeno constructivo y si la diferencia de fase generada es negativa, es un fenómeno destructivo (Notarnicola, 2016a; Salvia, 2016b), tal como se observa en la ilustración 10.




Ilustración 10: Representación vectorial del Speckle

La magnitud física que mide un SAR es el coeficiente de retrodispersión. Es un número normalizado y sin dimensiones, que compara la intensidad de la señal observada con la intensidad esperada, depende de parámetros del sensor, como lo son la potencia, la frecuencia, la polarización y el ángulo de incidencia y los parámetros inherentes al blanco, como es el contenido de humedad y la constante dieléctrica (CCRS, 2005; Salvia, 2016c).

La respuesta SAR en la vegetación, está vinculada a complejas interacciones de los parámetros del blanco (Riedel & Eckardt, 2013). Nos referimos a los parámetros del blanco a las características del canopy de la vegetación (tipo de cultivo, fenología, contenido de agua, dirección de surcos, etc.) y a los parámetros del suelo (humedad y rugosidad del suelo). La interacción de la señal SAR con la vegetación, ocurre de numerosas maneras, y depende tanto de su estructura como del medio subyacente (suelo, agua, etc.), como se muestra en la ilustración 11, puede ocurrir como la reflexión difusa (principalmente reflexión por volumen) con la vegetación, la interacción entre el suelo y la vegetación (doble rebote), como también la reflexión difusa desde el suelo.

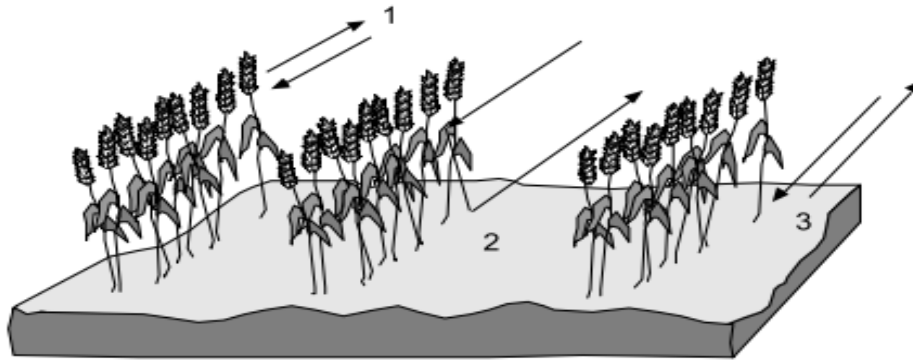


Ilustración 11: Interacción con la vegetación (CCRS, 2005)

La dispersión en volumen también es una situación común en la vegetación siendo el resultado de muchas interacciones entre la señal de radar y un medio homogéneo, pero que no es relativamente denso, la respuesta de la retrodispersión en volumen dependerá de las propiedades dieléctricas del material observado. La asociación entre la frecuencia y el ángulo de incidencia determina, como se observa una superficie, desde la imagen SAR en términos de rugosidad (Salvia, 2016a).

Capitulo Cuatro

Materiales y Métodos

A continuación en la ilustración 12 se muestra mediante un diagrama, la organización de los materiales y metodologías utilizadas en el trabajo de tesis.

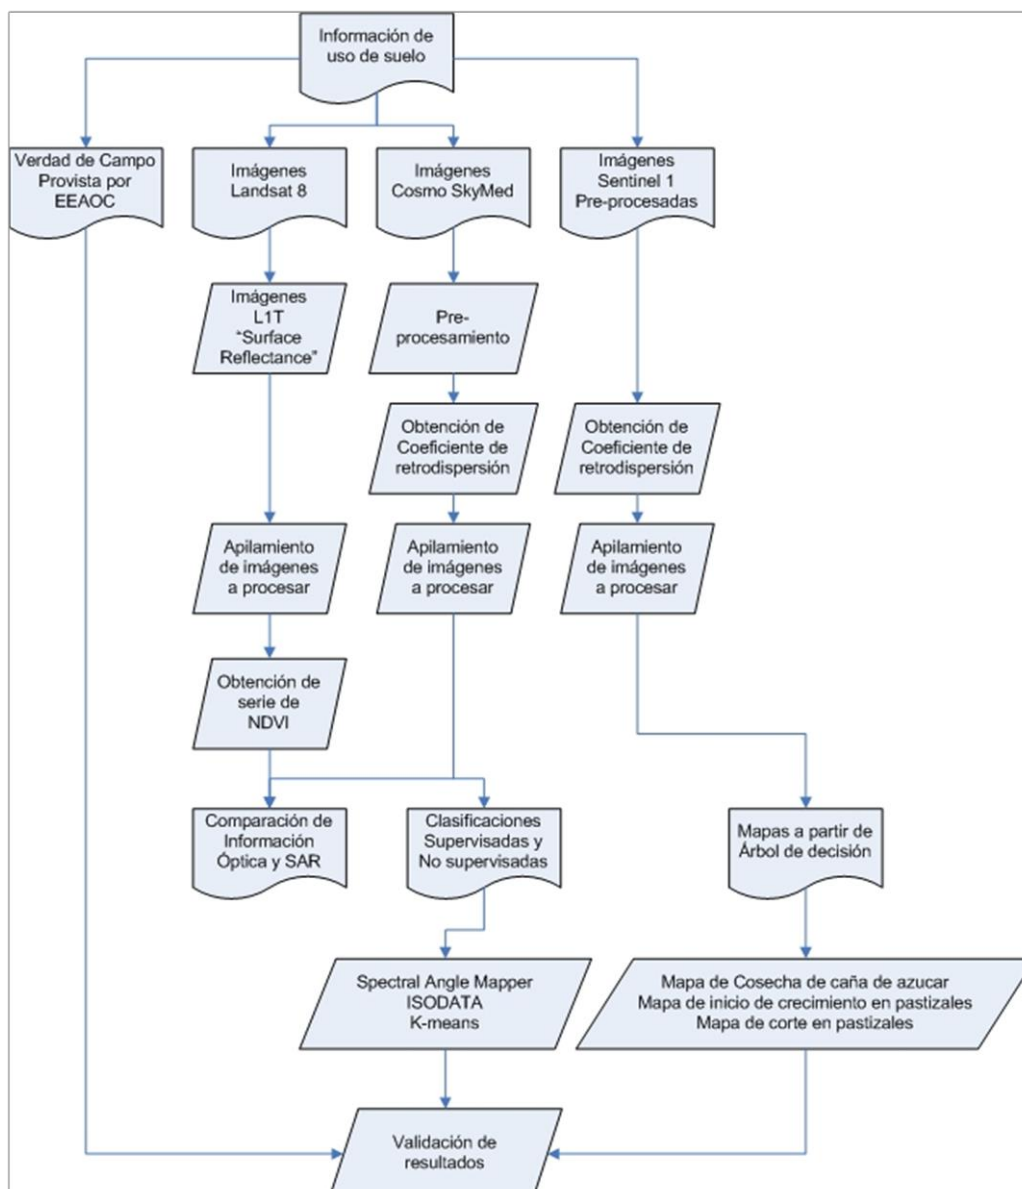


Ilustración 12: Diagrama de la metodología utilizada en el trabajo de tesis

4.1 Imágenes Cosmo SkyMed

Cosmo SkyMed (CSK) es una misión nacional italiana gestionada por la ASI (Agencia Espacial Italiana) que consta de un grupo de 4 satélites Radar (Roca, 2014). Los satélites de la constelación CSK operan en la región de las microondas, sobre la banda X (entre los 2,4-3,75 cm o 12,5 a 8 GHz). La constelación CSK ofrece los siguientes modos de operar, Spotlight, Stripmap y Scansar (Italian Space Agency, 2009). En la Tabla 1 se describen las características de los modos operativos de la constelación CSK, mientras que en la ilustración 13 se analizan gráficamente los mismos, pudiendo interpretar las diferencias entre los haces de adquisición del sistema radar de la constelación CSK.

Tabla 1: Modos operativos de la constelación Cosmo Skymed (Italian Space Agency, 2009)

	Spotlight	Stripmap		ScanSAR	
		HIMAGE	Ping Pong	Wide Región	Huge Región
Polarización	Single	Single	Dual	Single	Single
Ancho de barrido [km,km]	10X10	40X40	30X30	100X100	200X200
Franja accesible	~620 km				
Resolución Geométrica [m]	1	3	15	30	100

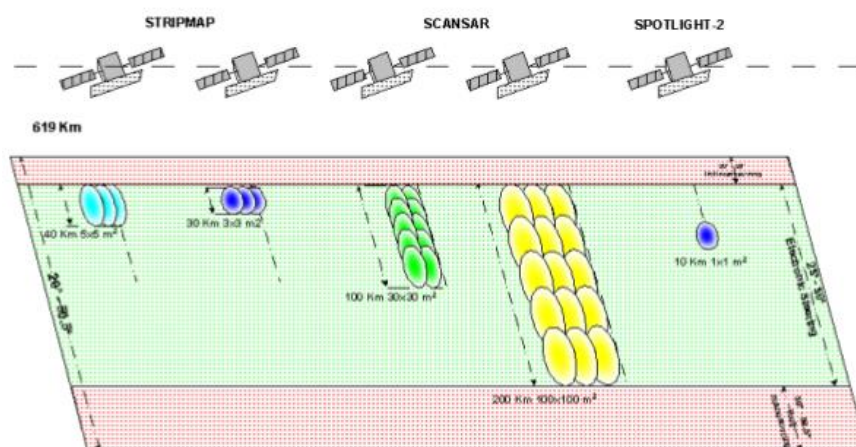


Ilustración 13: Modos operativos de la constelación Cosmo Skymed (Italian Space Agency, 2009)

Para el desarrollo de la tesis se utilizó un dataset de productos estándar, Cosmo SkyMed, nivel 1A, Single-look Complex Slant product (SLC), en el cual los datos crudos son enfocados en la proyección del rango o alcance y azimut. Este producto contiene la fase y cuadratura de los datos enfocados, ponderados y radiométricamente igualados (Italian Space Agency, 2009). La ilustración 14, muestra el conjunto de los 5 tipos de productos estándares disponibles para la constelación CSK.




Ilustración 14: Los 5 tipos de productos estándar en COSMO-SkyMed (Italian Space Agency, 2009)

El conjunto de imágenes utilizadas corresponde a adquisiciones sobre el área de estudio en la zona central de la Provincia de Tucumán, obtenidas durante el año 2015 y 2016, se enumeran en la Tabla 2 las características de estas imágenes ordenadas cronológicamente por fecha de adquisición. Las imágenes fueron facilitadas por la Comisión Nacional de Actividades Espaciales (CONAE) en el marco de la Maestría en Aplicaciones de Información Espacial, del Instituto Gulich (UNC-CONAE).

Tabla 2: Características de las Imágenes Cosmo SkyMed utilizadas

Imagen	Fecha	Modo	Polarización	Orbita	Angulo de Incidencia
1	16/1/2015	Stripmap Himage	HH	Descendente	40°
2	21/3/2015	Stripmap Himage	HH	Descendente	40°
3	22/4/2015	Stripmap Himage	HH	Descendente	40°
4	9/6/2015	Stripmap Himage	HH	Descendente	40°
5	27/7/2015	Stripmap Himage	HH	Descendente	40°
6	12/8/2015	Stripmap Himage	HH	Descendente	40°
7	15/10/2015	Stripmap Himage	HH	Descendente	40°
8	31/10/2015	Stripmap Himage	HH	Descendente	40°
9	16/11/2015	Stripmap Himage	HH	Descendente	40°
10	2/12/2015	Stripmap Himage	HH	Descendente	40°
11	18/12/2015	Stripmap Himage	HH	Descendente	40°
12	3/1/2016	Stripmap Himage	HH	Descendente	40°
13	19/1/2016	Stripmap Himage	HH	Descendente	40°
14	7/3/2016	Stripmap Himage	HH	Descendente	40°
15	26/5/2016	Stripmap Himage	HH	Descendente	40°
16	11/6/2016	Stripmap Himage	HH	Descendente	40°
17	2/11/2016	Stripmap Himage	HH	Descendente	40°

4.2 Imágenes Sentinel 1

Las misiones Sentinel se basan en una constelación de dos satélites para cumplir los requisitos de revisita y cobertura (European Spacial Agency, 2014). Sentinel 1 es una misión satelital que proporcionará continuidad a los datos del satélite ENVISAT y ERS (European Space Agency, 2013; European Space Agency et al., 2009). La misión Sentinel 1 opera en banda C (frecuencia central: 5.405 GHz), la revisita ocurre a los 6 días con los dos satélites en órbita. La prioridad de la misión son las aplicaciones para la vigilancia marina, el monitoreo de tierras y servicios de gestión de emergencia.

La constelación Sentinel 1, puede obtener imágenes en cuatro modos diferentes (European Space Agency, 2013), estos son:

- Strip Map: 80 km de pisada, 5 x 5 m de resolución espacial.

- Interferometric Wide Swath: 250 km de pisada, 5 x 20 m de resolución espacial.
- Extra-Wide Swath: 400 km de pisada, 20 x 40 m de resolución espacial
- Wave: 20 x 20 km, 5 x 5 m de resolución espacial.

Gráficamente en la ilustración 15 se pueden observar los diferentes modos de la constelación Sentinel 1.




Ilustración 15: Modos operativos de la constelación Sentinel 1 (European Space Agency, 2013)

El conjunto de imágenes utilizado en la tesis, corresponde a un dataset de productos de Nivel 1 GRD (*Ground Range Detected*) que consiste en datos SAR enfocados, multi-looked y proyectados en rango de tierra. No contienen información de fase. El producto resultante tiene unos píxeles de resolución cuadrada aproximada (European Space Agency, 2013).

Las imágenes utilizadas en la tesis, como se observa en la Tabla 3, son del modo Interferometric Wide Swath, que es el modo predeterminado en tierra (European Space Agency, 2013). Esta información fue provista por el Instituto de Observación de la Tierra, dependiente del EURAC, Bolzano, Italia.

Tabla 3: Características de las Imágenes Sentinel 1 utilizadas

Imagen	Fecha	Modo	Polarización	Orbita	Angulo de incidencia
1	26/2/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
2	22/3/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
3	15/4/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
4	9/5/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
5	2/6/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
6	26/6/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
7	20/7/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
8	1/8/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
9	13/8/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
10	25/8/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
11	6/9/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
12	18/9/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
13	30/9/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°
14	12/10/2015	Interferometric Wide Swath	VH	descendente	29.1° - 46.0°

4.3 Imágenes Landsat 8

Los datos obtenidos a partir de los satélites Landsat componen el registro más excelso de las superficies continentales de la Tierra visto desde el espacio, este registro comenzó con el lanzamiento del Landsat 1 a principios de los años setenta (Department of the Interior U.S. Geological Survey, 2016).

El objetivo de la misión Landsat 8 es proporcionar en el tiempo, Imágenes visibles e infrarrojas de alta calidad de todas las áreas terrestres y costeras de la Tierra, actualizando continuamente la base de datos de Landsat (Department of the Interior U.S. Geological Survey, 2016). El satélite Landsat 8 incorpora dos instrumentos, el Operational Land Imager (OLI), y un sensor térmico infrarrojo llamado Thermal Infrared Sensor (TIRS) (Ariza Alexander, 2013).

El sensor OLI presenta 8 bandas multispectrales de 30 metros de resolución espacial y una banda pancromática de 15 metros de resolución espacial; en cuanto al sensor TIRS, presenta dos bandas de 100 metros de resolución

espacial. La resolución radiométrica del Landsat 8 destaca con respecto a sus antecesores, ya que cuenta con 12 bits de resolución radiométrica. En la ilustración 16, se puede identificar la ubicación de cada una de las bandas espectrales que conforman este satélite.




Ilustración 16: Bandas espectrales del Landsat 8 (OLI y TIRS) y Landsat 7 (Department of the Interior U.S. Geological Survey, 2016)

El conjunto de imágenes Landsat 8 utilizadas para el desarrollo de la tesis corresponden al Path 230 Row 79 y a algunas imágenes del Path 231 Row 79. El conjunto de imágenes, es de nivel L1T, que consiste en un tipo de producto con datos radiométricamente corregidos y correcciones geométricas sistemáticas aplicadas (Ariza Alexander, 2013). Se denomina a este producto de nivel superior como “Surface Reflectance”, nos entrega el valor de reflectancia de superficie, corregido atmosféricamente a través de algoritmo de la NASA LaSRC (*Landsat 8 Surface Reflectance Code*) (Department of the Interior & U.S. Geological Survey, 2016), validado por Vermonte. El mismo concluye que existe una mejora del producto de reflectancia de superficie Landsat 8 (Vermote, Justice, Claverie, & Franch, 2016). En la Tabla 4, se observan el conjunto de imágenes Surface Reflectance de Landsat 8 utilizadas, que se obtuvieron del portal del servicio geológico de los estados unidos (Earth Explorer (USGS), n.d.), las imágenes fueron filtradas utilizándose aquellas con un porcentaje de nubes menor al 10%.

Tabla 4: Características de las Imágenes Landsat 8 utilizadas

Imagen	Fecha	Nivel	Path	Row	Proyección/ Datum
1	8/2/2015	L1T "Surface Reflectance"	230	79	UTM/WGS84
2	12/3/2015	L1T "Surface Reflectance"	230	79	UTM/WGS84
3	16/6/2015	L1T "Surface Reflectance"	230	79	UTM/WGS84
4	18/7/2015	L1T "Surface Reflectance"	230	79	UTM/WGS84
5	19/8/2015	L1T "Surface Reflectance"	230	79	UTM/WGS84
6	6/10/2015	L1T "Surface Reflectance"	230	79	UTM/WGS84
7	11/2/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
8	14/3/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
9	30/3/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
10	1/5/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
11	18/6/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
12	20/7/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
13	21/8/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
14	6/9/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
15	22/9/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
16	9/11/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
17	11/12/2016	L1T "Surface Reflectance"	230	79	UTM/WGS84
18	22/5/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84
19	25/7/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84
20	26/8/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84
21	11/9/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84
22	27/9/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84
23	13/10/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84
24	29/10/2015	L1T "Surface Reflectance"	231	79	UTM/WGS84

4.4 Datos de Campo

La información de campo de la zona de estudio principal en la Provincia de Tucumán, fue cedida para el desarrollo de este trabajo por la Estación Experimental Agroindustrial Obispo Colombres (*EEAOC*), y corresponde a la campaña agrícola de caña de azúcar 2015. La metodología de obtención de datos de campo se basa en información referida a manejo de cultivos e imágenes satelitales, a través de los sensores OLI, montado en la plataforma Landsat 8, HRVIR, a bordo del satélite SPOT 5 y LISS-III montados en el satélite IRS-P6

Resourcesat 2. Se realizaron análisis multitemporales, aplicando metodologías de análisis visual, análisis digital (clasificación multiespectral), y SIG, complementadas con relevamientos a campo (Soria, Fandos, Scandaliaris, & Carreras Baldrés, 2015). Finalmente en la ilustración 17, se observa la verdad de campo para contrastar con los resultados obtenidos de los procesamientos realizados sobre el área de estudio principal.

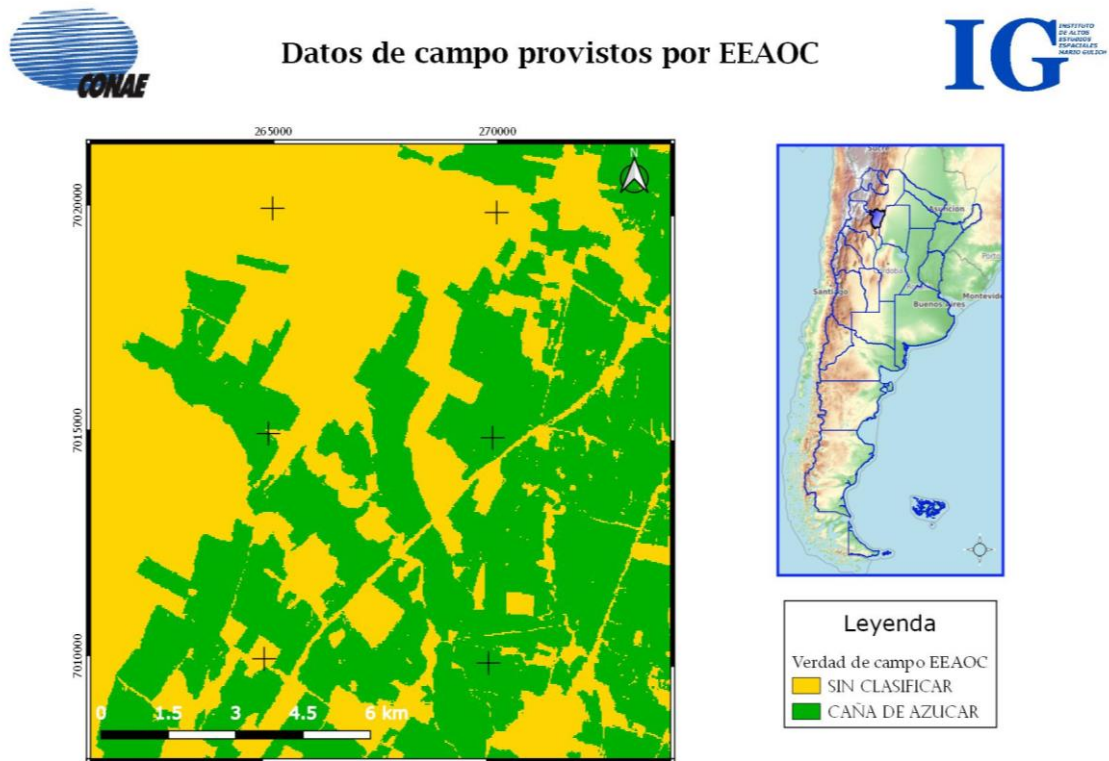


Ilustración 17: Verdad de campo, del área de estudio principal

La información de campo de la zona de estudio secundaria en la provincia autónoma de Bolzano, de Italia, fue proporcionada por el Instituto de Observación de la Tierra, dependiente del EURAC. Los datos a utilizar son el registro temporal de NDVI y el registro fotográfico de dos estaciones meteorológicas, Domef1500 ubicada en la latitud: 46.401002, longitud: 11.454211, como se contempla en la ilustración 18 y la estación Vimes1500, ubicada en la latitud: 46.686146, longitud: 10.579881, como se observa en la ilustración 19 como así también los valores temporales de temperatura del suelo.

En el Anexo 1, se adjuntan los valores que están presentes en los gráficos precedentes.

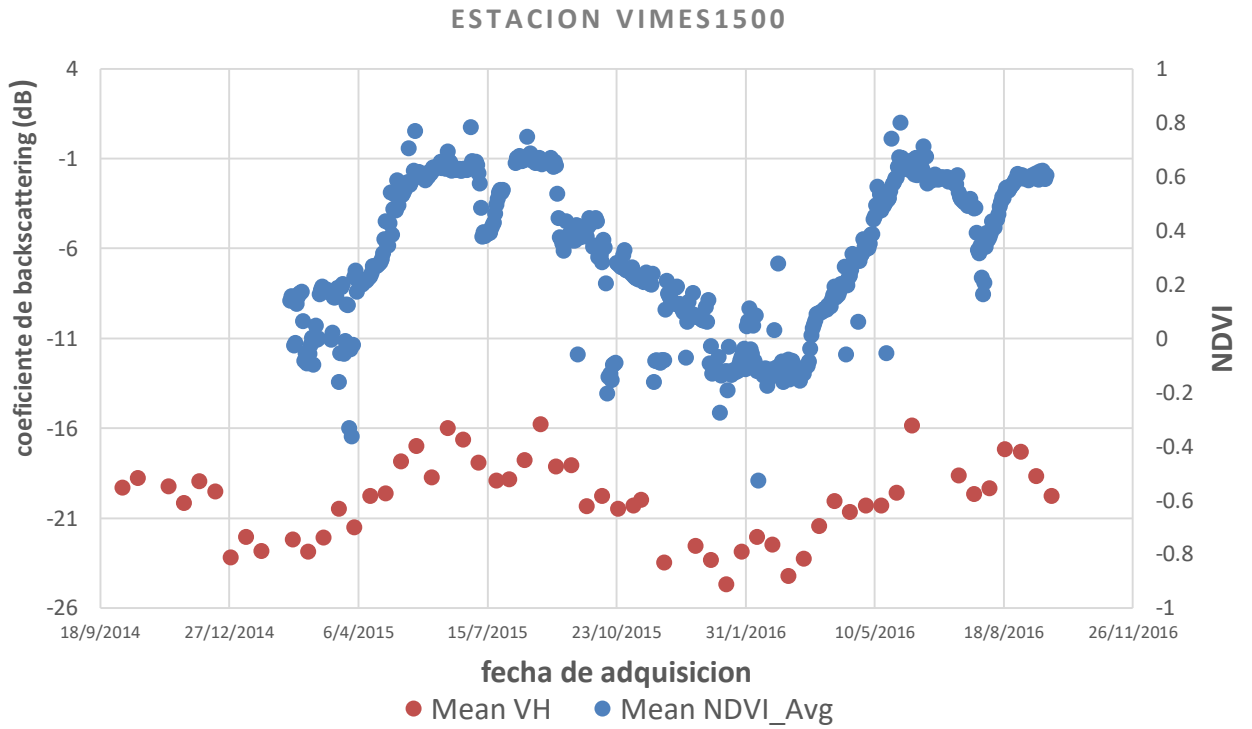


Ilustración 18: Valores promedio NDVI y dB en la estación VIMES 1500

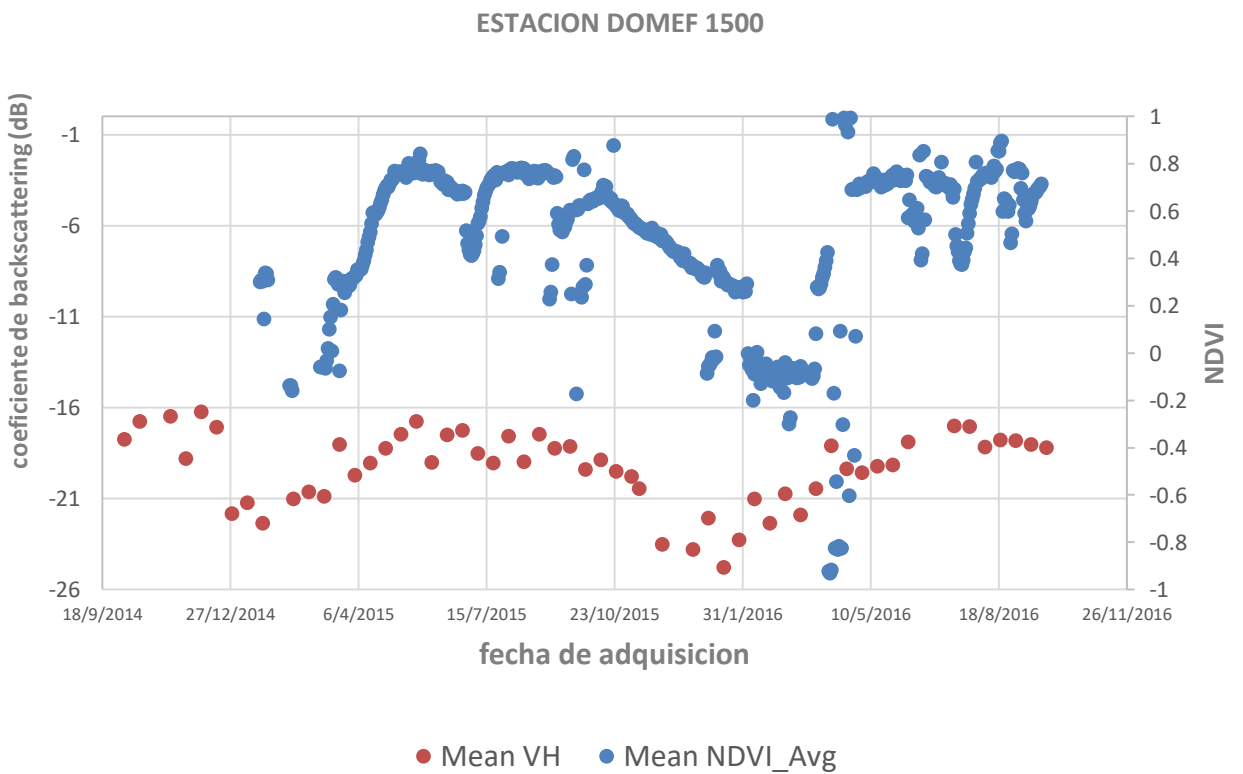


Ilustración 19: Valores promedio NDVI y dB en la estación DOMEF 1500

Las estaciones cuentan con información adicional de cámaras digitales automatizadas, “phenocams” y sensores de NDVI, que pueden supervisar el estado de la vegetación y los cambios ambientales durante largos períodos de tiempo para caracterizar de manera específica el ambiente. En la ilustración 20, se visualiza una toma de la phenocam, en la estación Vimes 1500.




Ilustración 20: Adquisición de la Phenocam, en estación Vimes 1500

4.5 Pre-procesamiento de imágenes

En esta sección se explica la metodología de pre procesamiento de las imágenes a utilizar. El pre procesamiento consiste en todos los pasos de procesamiento necesarios antes del uso de una imagen SAR para una aplicación específica (Notarnicola, 2016b). Se realiza para obtener una mejor interpretación de la imagen con la que estamos por trabajar, reducir el ruido presente y asociar un significado físico a los valores de la escena observados.

En el primer caso se describe el camino correcto para realizar el pre procesamiento a las imágenes Cosmo SkyMed, seguidas del pre procesamiento

que se utiliza para imágenes Sentinel 1, en esta ocasión a modo de ejemplo ya que el conjunto de imágenes trabajado ya estaba pre procesado. Ambos productos SAR se pre procesaron en el software SNAP, mientras que se utilizó ENVI para realizar lo mismo con en el producto L1T de Landsat 8.

4.5.1 Pre procesamiento Cosmo SkyMed

4.5.1.1 Calibración radiométrica

El cociente que se produce entre la variación de la cantidad de energía emitida por el sensor en relación a la que finalmente es recibida, lo denominamos retrodispersión. La calibración radiométrica corrige los factores de adquisición (Notarnicola, 2016b) y deriva en la representación de retrodispersión del radar de la superficie de la cual se obtuvo la escena, otorgándole un sentido físico a los valores de la imagen.

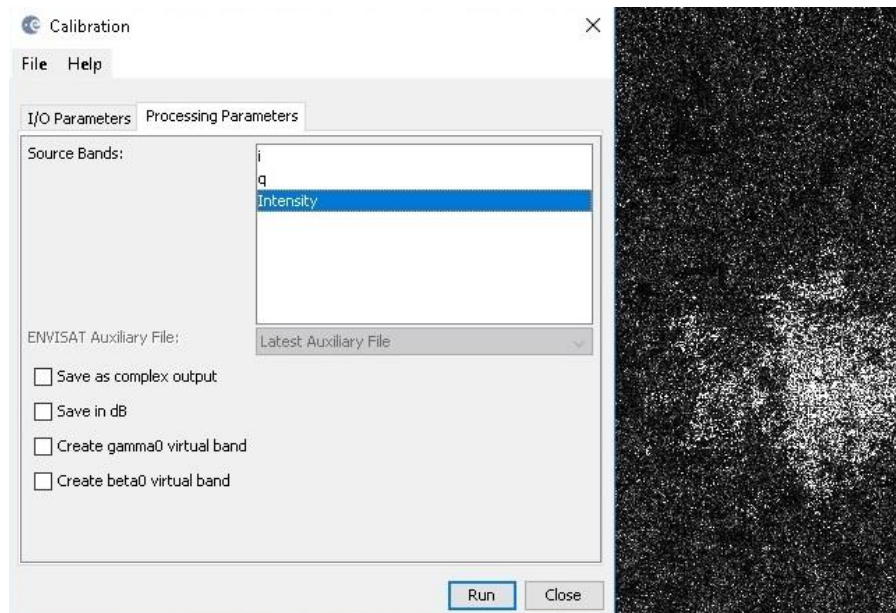


Ilustración 21: Ventana de calibración radiométrica y fracción de imagen CSK calibrada

La calibración radiométrica en SNAP, se realiza una vez abierta la imagen a pre procesar, a partir de la pestaña *Radar* → *Radiometric* → *Calibrate*, como se

muestra en la ilustración 21, se abre una ventana de diálogo que nos permite elegir el archivo de entrada, el destino del archivo generado con la imagen calibrada, como así también los parámetros del procesamiento.

4.5.1.2 Multilook

El proceso de multilook tiene por objeto reducir el nivel de ruido speckle de una imagen SAR. Esta reducción de ruido es posible en detrimento de la resolución espacial de la imagen, culminando en una nueva imagen con una mejora sustancial en la resolución radiométrica de la misma. En SNAP, como se observa en la ilustración 22, el procedimiento consta en ingresar en la pestaña *Radar*→*Multilooking*, se abre una ventana de diálogo, donde seleccionamos la imagen a la cual se aplicará multilooking, el destino en donde se guardará la misma, y los parámetros del procesamiento. En nuestro caso se aplicó al conjunto de imágenes, multilooking de 5 looks en Rango y 5 looks en Azimut.

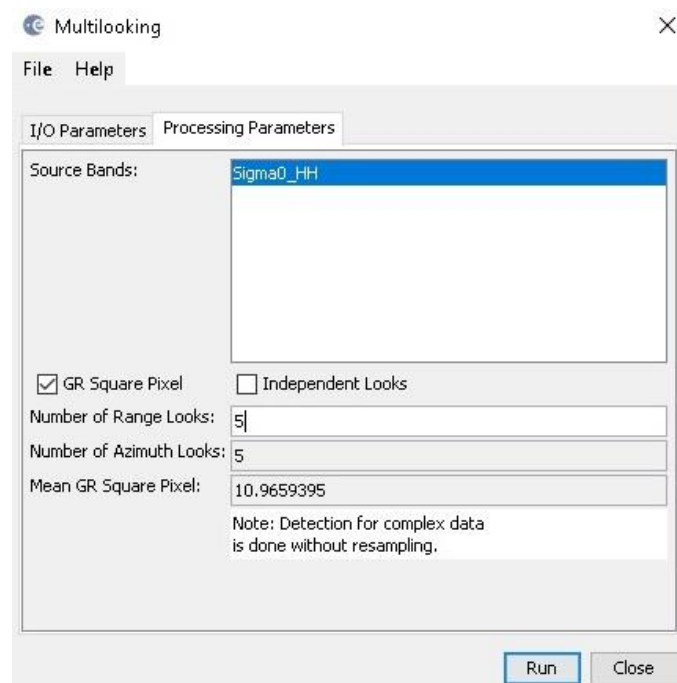


Ilustración 22: Ventana de multilooking, en SNAP

En la ilustración 23, se advierte en un ejemplo cómo se reduce el ruido visualmente, antes y después de aplicar el proceso de multilooking en un recorte de una imagen CSK.




Ilustración 23: Antes y después de aplicar multilook en una imagen CSK, visualización en Potencia (SNAP)

4.5.1.3 Filtro de Speckle

El speckle como ya fue definido, es básicamente interferencia a gran escala. La reducción del speckle también se lograra a través de la aplicación de numerosos filtros, entre ellos los adaptivos preservan los bordes de la ventana de procesamiento y las propiedades locales del área bajo análisis (CCRS, 2005), aumentando la precisión en la estimación del coeficiente de retrodispersión. En SNAP, como se observa en la ilustración 24, el procedimiento consta en ingresar en la pestaña *Radar* → *Speckle Filtering* → *Single Product Spackle Filter* (para aplicar el filtro a una imagen individual), se abre una ventana de diálogo, donde se selecciona la imagen a la cual se le aplicará el filtro de Speckle y el destino en donde se guardará la misma, como así también los parámetros del procesamiento. A las imágenes Cosmo SkyMed se le aplicaron filtros Gamma Map (más adecuado para la agricultura) y que presupone que la intensidad (sin speckle) de la escena tiene una distribución Gamma (CCRS, 2005). Este filtro es

un filtro adaptivo y se caracteriza por la preservación de los bordes de la escena, teniendo en cuenta el ambiente local del pixel, el filtro Gamma Map se fundamenta en la hipótesis de que la escena con ausencia de Speckle posee una distribución Gamma, como ocurre en áreas agrícolas.

En la ilustración 24, se observa cómo se aplicó un filtro de estas características, sobre una ventana de procesamiento de 3 por 3.

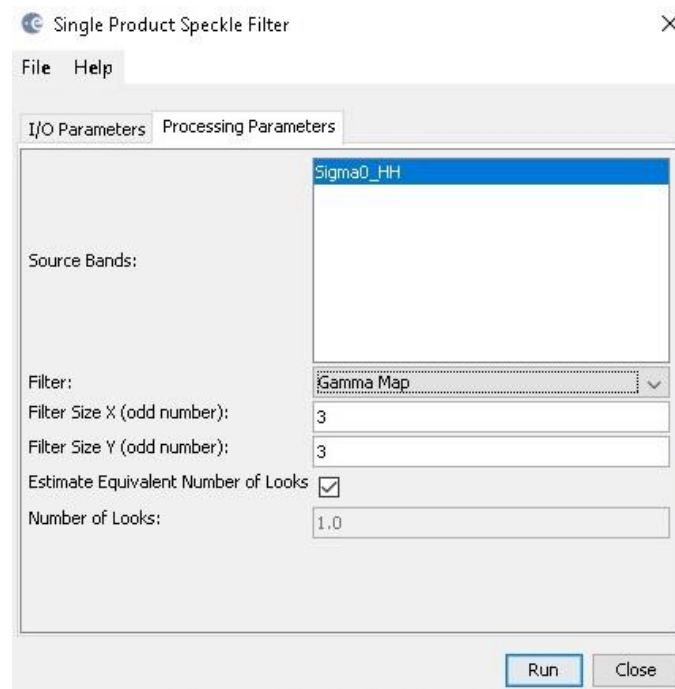


Ilustración 24: Ventana de filtrado speckle, en SNAP

En la ilustración 25 se pueden observar las diferencias visuales entre una imagen calibrada radiométricamente y con multilooking con la posteriormente filtrada para reducir el speckle.




Ilustración 25: Antes y después de aplicar filtro Gamma Map en una imagen CSK, visualización en Potencia (SNAP)

4.5.1.4 Corrección de terreno

Una de las prácticas más importantes del pre procesamiento es ubicar a nivel del terreno los píxeles de la imagen. Esto permite tanto disminuir las distorsiones geométricas ocasionadas en la adquisición lateral del SAR como así también adaptar los píxeles de la imagen a las características del terreno. Para realizar este procesamiento en SNAP se acudió a la pestaña *Radar* → *Geometric* → *Terrain Correction* → *Range-Doppler Terrain Correction* se abre una ventana de dialogo, donde se seleccionó la imagen a la cual se le aplicará la corrección terrena y el destino en donde se guardará la misma, como así también los parámetros del procesamiento. Dentro de los parámetros de procesamiento, como se observa en la ilustración 26, se utilizó un Modelo Digital de Elevación (DEM) que en el Software SNAP tiene la opción de auto descarga para la zona a procesar, utilizando un DEM SRTM 1sec, de la zona de estudio, la interpolación utilizada por defecto es la bilineal y también se definió como proyección en mapa para al conjunto de imágenes procesadas las coordenadas UTM WGS84.

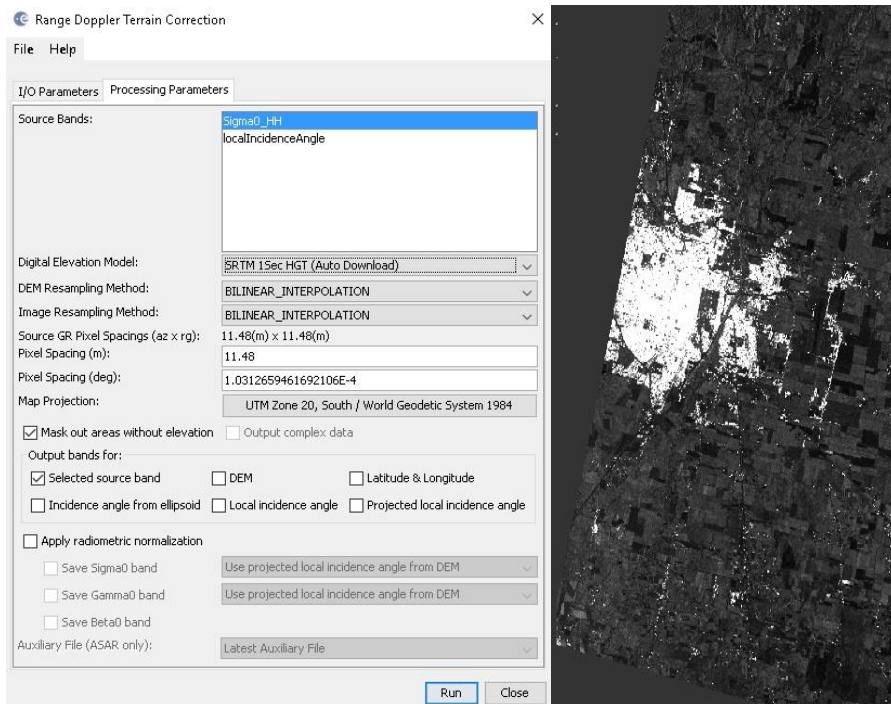


Ilustración 26: Ventana de corrección terrena, en SNAP y fracción de imagen CSK corregida

Para que esto pueda realizarse sin errores en un grupo extenso de imágenes a pre procesar, es recomendable utilizar la opción que existe en SNAP de realizar un grafo de procesamiento, como se observa en la ilustración 27. Para esto es necesario detallar el orden de pre procesamiento, comenzando por la imagen a pre procesar, explicitar los parámetros adecuados y definir el archivo de salida en donde se guardará la imagen resultante.

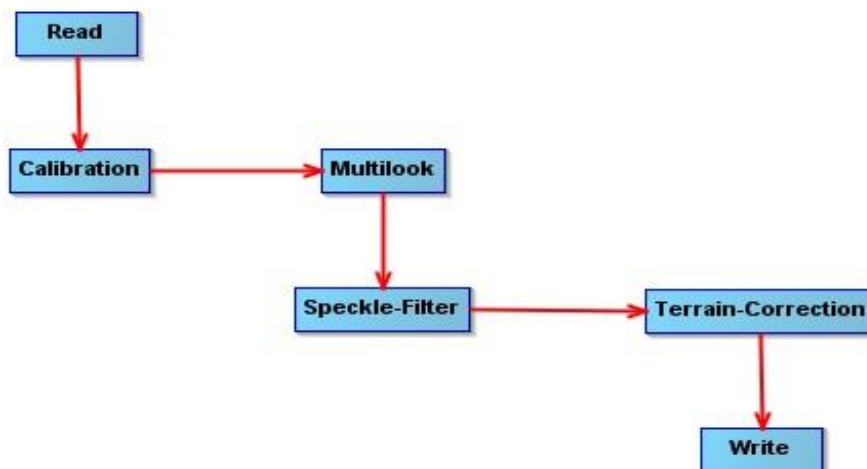


Ilustración 27: Grafo de procesamiento para imágenes CSK, en SNAP

4.5.1.5 Co-registro de imágenes

Este procesamiento resulta útil en el caso de análisis de múltiples imágenes adquiridas sobre la misma área (por ejemplo, análisis de series de tiempo), corrigiendo los efectos relativos de escala, rotación y desplazamiento traslacional entre las imágenes consideradas (Notarnicola, 2016b), permitiendo ordenarlas pixel a pixel.

4.5.2 Pre procesamiento Sentinel 1

En cuanto a las imágenes Sentinel 1, se aclara que fueron facilitadas por EURAC Research, en un dataset ya pre procesado. Sin embargo, es necesario para la comprensión de los lectores de esta tesis, saber que hay alguna sustancial diferencia entre el pre procesamiento de imágenes Cosmo SkyMed y Sentinel 1 de Nivel 1 GRD, en el software de la ESA, SNAP, estas se enumeran a continuación.

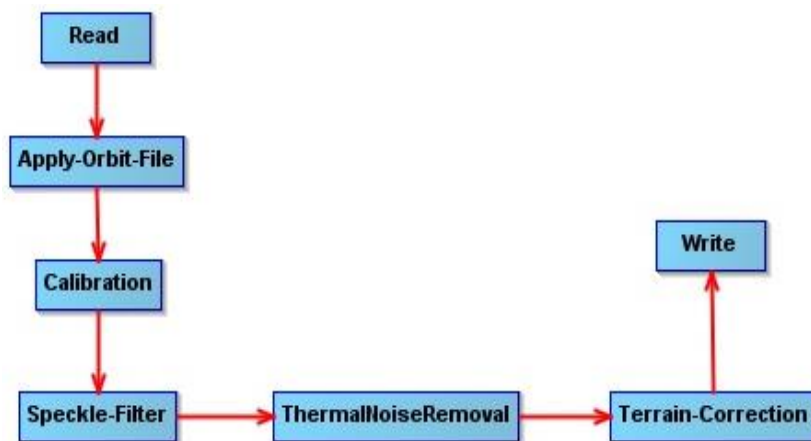


Ilustración 28: Grafo de procesamiento para imágenes Sentinel 1, en SNAP

La ilustración 28, señala como debería ser el grafo de pre procesamiento que es adecuado para ejecutar sobre una imagen Sentinel 1.

4.5.2.1 Archivo de órbita

Los vectores que corresponden al estado de órbita proporcionados en el metadato de un producto SAR generalmente no son precisos. El archivo de la órbita proporciona información precisa de la posición y de la velocidad del satélite, y se produce unas pocas semanas después de la adquisición. El software SNAP permite para algunos sensores, como es el caso de Sentinel 1 que el archivo de órbita precisa, pueda aplicarse en la imagen. Para realizar este procesamiento en SNAP se acudió a la pestaña *Radar* → *Apply Orbit File*, se abre una ventana de dialogo, donde se selecciona la imagen a la cual se le aplicará la corrección de órbita y el destino en donde se guardará la nueva imagen, en la otra pestaña encontramos los parámetros del procesamiento. Dentro de los parámetros de procesamiento, como se observa en la ilustración 29, se seleccionó el vector de estado de órbita que corresponde a Sentinel 1.

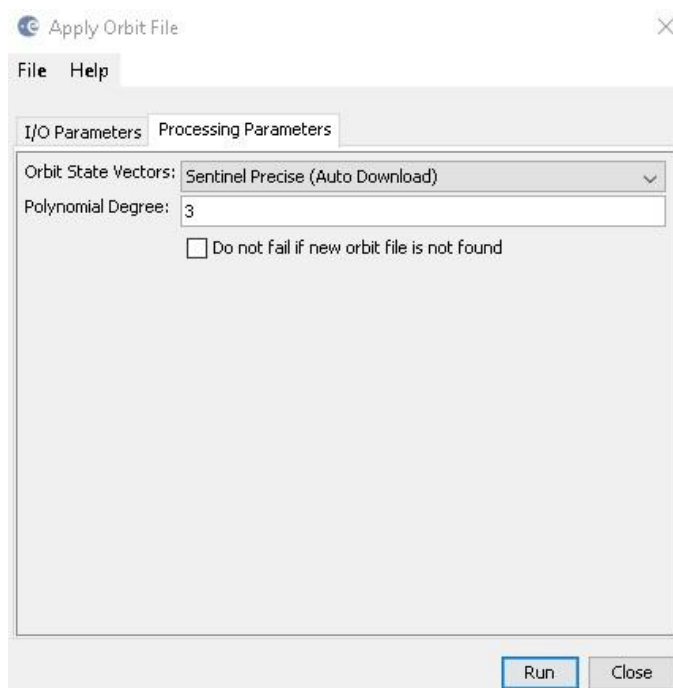


Ilustración 29: Ventana de corrección orbital, en SNAP

4.5.2.2 Eliminación de ruido térmico

Es la corrección de ruido térmico y puede aplicarse a los productos SLC Sentinel 1 Nivel 1 así como a los productos GRD Nivel 1 que no han sido corregidos. Para realizar este procesamiento en SNAP se acudió a la pestaña *Radar* →

Radiometric → *S1 Thermal Noise Removal*, se abre una ventana de dialogo, donde se seleccionó la imagen a la cual se le aplicará la eliminación del ruido térmico y el destino en donde se guardará el producto de la corrección, en la otra pestaña se encuentran los parámetros de procesamiento. Allí como se observa en la ilustración 30, simplemente se debe tildar la opción de remover el ruido térmico.

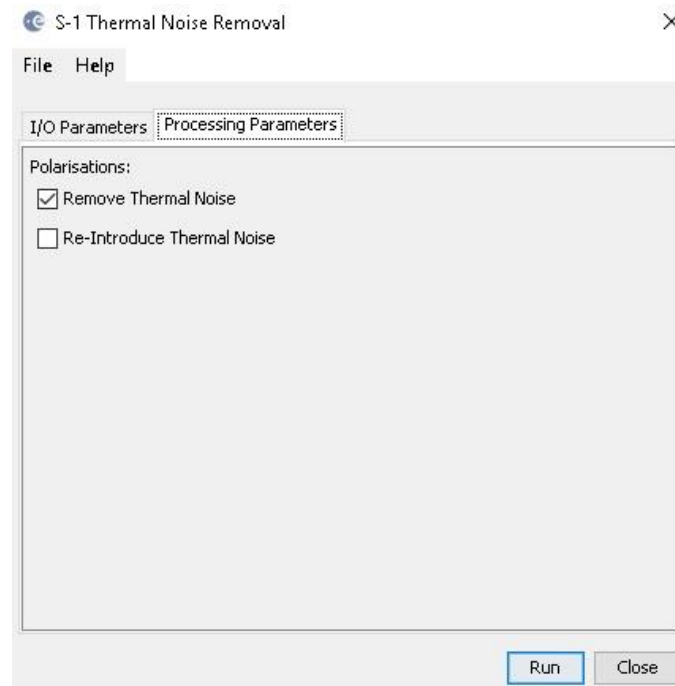


Ilustración 30: Ventana de eliminación de ruido térmico, en SNAP

Un error habitual en el pre procesamiento de imágenes Sentinel 1, modo Interferometric Wide Swath, Nivel 1 GRD, es aplicar la reducción de ruido por multilooking, pero resulta imperioso conocer que este tipo de productos ya tiene aplicado el multilook, como lo describe su manual de usuario (European Space Agency, 2013).

4.5.3 Pre procesamiento Landsat 8

En el caso de las imágenes Landsat 8, nivel de procesamiento L1T “Surface Reflectance” llevadas a reflectancia de superficie a través del algoritmo LaSRC (Vermote et al., 2016), no es necesario realizar correcciones atmosféricas, en cambio resulta necesario aplicar a las bandas de la imagen un factor de conversión (Department of the Interior & U.S. Geological Survey, 2016), que permite ajustar los valores de pixel a la escala de reflectancia (entre 0 y 1), dando una interpretación física a estos valores. Este procesamiento se puede observar en la formula [1], el mismo se realizó en el software ENVI, a partir de una matemática de bandas que ajusto a cada una de las bandas de las imágenes a utilizar, descritas en la tabla 4.

$$\text{Factor de escala} = \text{Banda de la imagen} \times (0.0001) \quad [1]$$

4.6 Procesamiento de imágenes

4.6.1 Índices Espectrales

La complejidad del espectro electromagnético implica que resulte conveniente utilizar aproximaciones más simples entre diferentes porciones del mismo, que vinculen a los parámetros biofísicos con las observaciones satelitales (Kandus, 2016a). Un índice espectral es el resultado de la combinación de diferentes bandas espectrales, que proporcionan un grado de coherencia mayor entre la observación satelital y la superficie bajo estudio, facilitando el proceso de interpretación.

Existen numerosos índices espectrales, es de nuestro interés enfocarnos en los índices de vegetación, que aprovechan el contraste existente entre los valores

de reflectancia entre la banda Roja y la correspondiente al Infrarrojo Cercano (Chuvieco Salinero, 2006), asociándolo con el estado general de la vegetación.

El NDVI, es un índice usado para estimar la cantidad, calidad y desarrollo de la vegetación (Rouse et al., 1974). Este índice se utiliza para reducir la dimensionalidad de la información de las imágenes Landsat 8, y para su desarrollo se trabaja con las bandas 5 (Infrarrojo Cercano) y 4 (Rojo) de este sensor como se muestra en la fórmula [2]. Este tiene las ventajas de la sencillez para su cálculo, y la facilidad de interpretación de los parámetros biofísicos de la vegetación (Merg, Petri, Bodoira, & Nini, 2011). Mientras que sus limitaciones destacan el efecto distorsionador del suelo y la saturación del índice frente a valores altos de área foliar (Violini, 2016).

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad [2]$$

El índice fue calculado en el software ENVI, por una matemática de bandas, como se observa en la fórmula [3] los resultados de esta transformación se sitúan entre -1 y +1 y representan individualmente la cantidad de vegetación presente en el pixel.

$$NDVI = \frac{float(B5) - float(B4)}{float(B5) + float(B4)} \quad [3]$$

En la Tabla 5, se aprecia como los valores de NDVI pueden llevarse a algún tipo de escala que permita agrupar los valores del índice, a priori se entiende que los valores negativos del índice se asocian a la existencia de valores en el Infrarrojo Cercano, menores a los valores en el Rojo, situación que se observa con la presencia de agua, nieve o nubosidad.

Tabla 5: Clasificación de los valores de NDVI, elaborado por (Lopez Perez, Martinez Menes, & Fernandes Reynoso, 2015)

<i>clasificación</i>	<i>valor</i>
<i>Nubes y agua</i>	< 0.01
<i>Suelo sin vegetación</i>	0.01 - 0.1
<i>Vegetación ligera</i>	0.1 - 0.2
<i>Vegetación mediana</i>	0.2 - 0.4
<i>Vegetación alta</i>	> 0.4

Posteriormente a la realización del índice NDVI, en todas las imágenes Landsat 8 disponibles para trabajar, se realizó el apilamiento de las mismas, en el software ENVI, que permitirá hacer una interpretación temporal del crecimiento del cultivo de la caña de azúcar como así también comparar la respuesta temporal del NDVI con los valores de coeficiente de retrodispersión para el mismo periodo y zona analizada de las imágenes Cosmo SkyMed.

Las imágenes Landsat 8 del dataset utilizado fueron seleccionadas con el criterio de que posean un valor menor al 10% de cobertura nubosa, sin embargo sobre aquellas imágenes que la presencia de nubes se encontraba sobre el área de estudio fueron eliminadas a través de una máscara de nubes a partir de la banda de evaluación de calidad en Landsat 8. La banda de evaluación de calidad contiene información adicional de combinaciones de bits de relleno de la superficie, la atmósfera y las condiciones de sensores (Ariza Alexander, 2013). La banda de evaluación de calidad, es un archivo de 16 bits, en la cual los valores de esta se asignan a diferentes coberturas con diferentes niveles de confianza. La presencia de nubes se asume con valores entre 11 y 15 bits, el número decimal que se asocia a un nivel de confianza alto de presencia de nubes es todo número mayor a 49152. En la ilustración 31, se resalta el valor de un pixel perteneciente a una zona con nubes (valor decimal 53248), y se puede de esta manera comprobar que el valor se encuentra por encima del límite anteriormente mencionado.

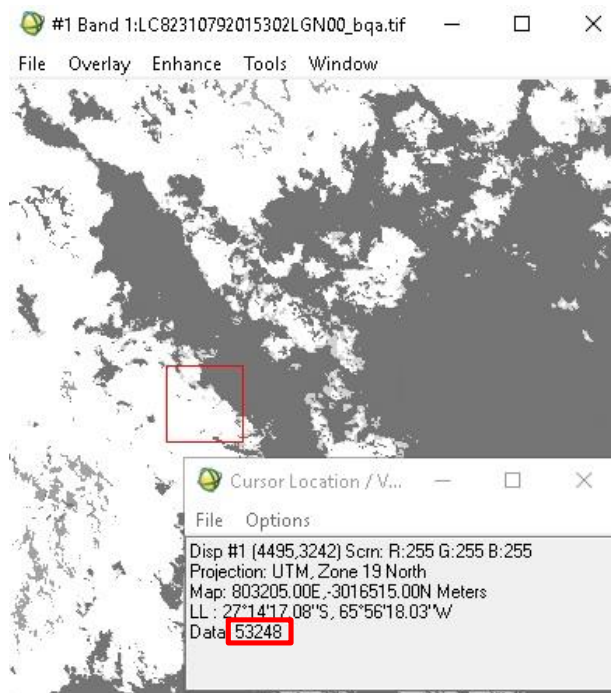


Ilustración 31: Ejemplo de valor del valor decimal de pixel en BQA, de Landsat 8

Finalmente, se genera una máscara de nubes a partir de la banda de evaluación de calidad, que se realiza por una sencilla matemática de bandas que selecciona aquellos valores menores al límite decimal 49152. Posteriormente, se aplica sobre las bandas 3 y 4 que intervienen en la generación del índice NDVI, para que este quede realizado con la corrección de nubes adecuada.

Una vez generados todos los índices NDVI, del conjunto de imágenes Landsat 8 disponibles, se apila temporalmente, en el software ENVI, Teniendo en cuenta el orden cronológico y la proyección adecuada de las imágenes, además se utiliza la opción de rango exclusivo, que contiene sólo la extensión de datos donde se superponen todos los archivos (Harris Geospatial Solution, 2013).

4.6.2 Comparación de datos ópticos y SAR

Los datos satelitales de los sensores Landsat 8 y Cosmo SkyMed que pertenecen a la zona de estudio principal, en la provincia de Tucumán, Argentina,

se comparan en el periodo correspondiente a los años 2015 y 2016, a partir de la respuesta de NDVI y dB en el tiempo. Resulta de interés aumentar el nivel de comprensión entre la información que proveen estos sensores. El análisis exploratorio que aquí se propone, persigue aumentar el conocimiento entre la información óptica y la información SAR orientada en el abordaje fenológico de diferentes usos de suelo, particularmente en la caña de azúcar.

Inicialmente se obtienen regiones de interés (ROI) desde el software ENVI, estas muestras persiguen la finalidad de obtener la estadística, de zonas homogéneas o de poca variabilidad de un determinado uso del suelo, para entender el comportamiento temporal de la distribución de píxeles de esa región en las bandas que componen el apilamiento de imágenes, tanto en óptico como en SAR.

En la ilustración 32, se observa por ejemplo, una parcela homogénea desde Google Earth, de la cual se obtienen píxeles puros, que posteriormente será convertida en una ROI, tanto para imágenes Ópticas y SAR.




Ilustración 32: Captura de Google Earth, correspondiente al lote homogéneo de una ROI de caña de azúcar

En este caso corresponde a un lote de caña de azúcar y puede validarse de dos maneras, a través de los datos de campo o en algunos casos a partir de la

herramienta de Google "Street View" que nos permite hacer una evaluación visual del lote, siempre y cuando esté disponible en la fecha de análisis. Como la ilustración 33 revela, esto es posible solo en las zonas donde este producto de Google está disponible.

La posibilidad de contar con un registro visual como este, es de importante valor en los estudios en los que la información de campo para la validación, es escasa o inexistente. Permitiendo trabajar sobre diferentes usos de suelo a través de esta singular aproximación visual.



Ilustración 33: Captura de Google Street View, correspondiente al lote de caña de azúcar de la ilustración 32

Finalmente, para poder analizar una misma zona del territorio sobre la información disponible de los dos sensores, se utiliza en el software ENVI la opción "Reconcile ROI by Map", que transfiere la información de un ROI creado en una imagen a otra con diferente resolución espacial. La ilustración 34, proporciona el resultado de dos ROI, en ambos apilamientos Ópticos y SAR, de los que se obtendrá posteriormente la comparación en función a la respuesta temporal del NDVI y dB.

Si bien los resultados en cuanto a los valores en dB del coeficiente de retrodispersión son exploratorios estos se asemejan específicamente en caña de azúcar a los valores que se encuentran en los estudios de (Lin, Chen, Pei, Zhang, & Hu, 2009; Paradis et al., 2010).



Ilustración 34: ROI de caña de azúcar en imagen CSK a la izquierda y en NDVI derivado de Landsat 8 a la derecha

4.6.3 Clasificaciones

Si bien la explicación formal de que es una clasificación fue realizada en la introducción, la misma hace referencia al proceso de asignar los valores de un grupo de píxeles a una categoría. Este proceso es ejemplo de aplicar la resolución de un problema inverso, es decir que a partir de una observación satelital con ciertas propiedades, preguntarse qué medio y qué características del medio generan esas propiedades de reflectividad o coeficiente de retrodispersión, para el caso de estudio.

La clasificación de cultivos debe ser abordada como una sucesión de etapas (Vazquez Espinoza de los Monteros, 2015), que consiste en la adquisición de imágenes, el pre procesamiento y extracción de información para finalmente elegir el método y algoritmo de clasificación.

Se utilizan diferentes clasificadores, para analizar la información disponible de las áreas de estudio, y cumplir con los objetivos planteados en el capítulo 1.

Existen numerosos algoritmos y métodos de clasificación de imágenes, estos últimos pueden ser supervisados o no supervisados. La clasificación supervisada requiere del conocimiento previo de las clases de información, se seleccionan las clases y se agrupan en áreas de entrenamiento y testeo. Se asume que las áreas de entrenamiento son la fiel representación de las categorías temáticas (Chuvienco Salinero, 2006). La clasificación no supervisada en cambio, no requiere de un conocimiento previo de la zona, la finalidad es la de encontrar agrupamientos naturales de los pixeles. A posteriori, cuando se deben asignar las clases el analista determinará a que corresponde cada clase (Kandus, 2016b).

4.6.3.1 Árboles de decisión

El clasificador por arboles de decisión es un clasificador no paramétrico, es decir que la distribución de los datos no es definida a priori. Es un método en el que destaca la sencillez y eficiencia. La técnica consiste en discriminar secuencialmente cada categoría a clasificar, de acuerdo a ciertos criterios seleccionados por el analista (Bustos, Frery, Lamfri, & Scavuzzo, 2004).

La ramificación dicotómica que genera este clasificador, lo hace adecuado para determinar eventos que presenten variación tanto espacial y temporal, como puede ser en este caso para determinar el momento de cosecha en la caña de azúcar y el momento de corte en los pastizales naturales. En la ilustración 35, se representa el esquema de jerarquía del método de árbol de decisión.




Ilustración 35: Esquema de jerarquía del Árbol de decisión

En el caso de la caña de azúcar, la cosecha descrita en el capítulo 1, tiene una gran dispersión temporal. Es una práctica dependiente de las condiciones climáticas y tiene una incidencia alta sobre los costos de producción. A partir del índice NDVI generado sobre imágenes Landsat 8, es posible correlacionar la caída en los valores del índice con el momento de cosecha.

En la ilustración 36, se graficó el comportamiento fenológico de un lote homogéneo de caña de azúcar indirectamente a partir de los valores del NDVI, demarcando el momento de la caída del índice y se puede relacionar con la zafra de caña de azúcar. Si se pudieran superponer todos los lotes de Caña en la región de análisis, se podría manifestar que las caídas del índice NDVI no ocurren en el mismo tiempo, justificando en este caso el uso del clasificador de árbol de decisión, para realizar un mapa de la cosecha de la caña de azúcar a partir de imágenes ópticas.




Ilustración 36: Comportamiento fenológico de una ROI de caña de azúcar

Para corroborar este hecho anteriormente mencionado, se realizaron en el lenguaje de programación R, gráficos de caja (Boxplot) de ROI homogéneas tanto en caña de azúcar en Tucumán y pastizales naturales en Italia.

Un gráfico de caja, permite identificar claramente la distribución de los datos y sus principales características. Como herramienta visual se puede utilizar para ilustrar los datos, para estudiar simetría y las colas como así también supuestos sobre la distribución y comparar diferentes poblaciones (Correa & Gonzalez, 2002).

El gráfico boxplot suministra información sobre los valores mínimo y máximo, mediana y los cuartiles 1 y 3, como así también sobre la existencia de valores atípicos y la simetría de la distribución. Para este caso el uso de la cintura en los gráficos de caja se utilizó para comparar la distribución de las ROI en diferentes fechas ya que si las cinturas de dos gráficos de caja se separan se puede decir con un 95 por ciento de confianza que dos medianas son diferentes (Chambers, Cleveland, Kleiner, & Tukey, 1983; Ferral, 2013).

La misma metodología de clasificación, también se utilizó para detectar el inicio de temporada en el crecimiento y los momentos de corte de pastizales naturales, en la región del Sud Tírol, Bolzano. En ambas situaciones la metodología presenta adicionalmente una serie de dificultades asociadas por trabajar con imágenes SAR, esto se explica en los puntos 5.2.2 y 5.2.3 del capítulo siguiente, el procedimiento realizado para la obtención de este producto.

4.6.3.2 Spectral Angle Mapper

Spectral Angle Mapper (SAM) es un clasificador que compara las firmas de referencia, obtenidas en este caso de ROI temporales de caña de azúcar y otros usos de suelo (Cítricos y Bosques) que pudieron diferenciarse en base al comportamiento fenológico en el tiempo. El algoritmo mide las diferencias angulares en la posición del espacio de características (Weeks, 2010). El algoritmo determina la similitud espectral entre dos espectros calculando el ángulo entre los espectros y tratándolos como vectores en un espacio con dimensionalidad igual al número de bandas (Harris Geospatial Solution, 2013). Este algoritmo pretende ser utilizado de manera exploratoria, para evaluar su comportamiento en el conjunto de imágenes CSK.

En la ilustración 37, se observa como SAM determina la similitud de un espectro de prueba con un espectro de referencia (Kruse et al., 1993).




Ilustración 37: Espectro de referencia y espectro de prueba (Kruse et al., 1993)

Para adaptar el uso de este clasificador al conjunto de datos SAR, es necesario describir el comportamiento temporal de la respuesta SAR, para tal fin se realizó un conjunto de firmas temporales en dB, tanto en caña de azúcar, que es nuestro cultivo de interés y en otros dos usos de suelo (cítricos y bosques) por medio de ROI obtenidas en base a lo expresado en la metodología del punto 4.6.2, para facilitar la clasificación, también se realiza un análisis de separabilidad para corroborar las diferencias en dichas firmas.




Ilustración 38: Firmas Temporales de diferentes usos de suelo

Si bien gráficamente, como se puede observar en la ilustración 38, existen diferencias sustanciales en el comportamiento de los usos de suelo. Durante el periodo de tiempo bajo análisis, se aplica el proceso de “*compute ROI separability*” en el software ENVI en el que se calculan las distancias de Jeffries-Matusita y la de Divergencia Transformada informándose para cada par de ROI, y así calcular la separabilidad temporal entre ellas para un archivo de entrada dado. Este cálculo indica cuan estadísticamente independientes son los pares de ROI seleccionados. Los valores superiores a 1,9 indican que los pares ROI tienen una buena separabilidad (Harris Geospatial Solution, 2013), a su vez valores menores indican mayor dificultad en separabilidad estas firmas temporales (se ejemplifica con dos ROI de bosque esta situación).

En la ilustración 39, se advierten los resultados indicando la existencia de buena separabilidad entre los pares de ROI seleccionados.

```

Input File: Stack_SigmaHH_29090
ROI Name: (Jeffries-Matusita, Transformed Divergence)

Caña_M1 [Green] 164 points:
Citricos_2 [Green] 176 points: (1.99891084 1.99956206)
Bosque_1 [Blue] 135 points: (1.99564005 1.99999999)
Bosque_2 [Yellow] 129 points: (1.99581522 2.00000000)

Citricos_2 [Green] 176 points:
Caña_M1 [Green] 164 points: (1.99891084 1.99956206)
Bosque_1 [Blue] 135 points: (1.95657120 1.99993609)
Bosque_2 [Yellow] 129 points: (1.95525485 1.99999949)

Bosque_1 [Blue] 135 points:
Caña_M1 [Green] 164 points: (1.99564005 1.99999999)
Citricos_2 [Green] 176 points: (1.95657120 1.99993609)
Bosque_2 [Yellow] 129 points: (0.96147606 1.06532434)

Bosque_2 [Yellow] 129 points:
Caña_M1 [Green] 164 points: (1.99581522 2.00000000)
Citricos_2 [Green] 176 points: (1.95525485 1.99999949)
Bosque_1 [Blue] 135 points: (0.96147606 1.06532434)

Pair Separation (least to most);
Bosque_1 [Blue] 135 points and Bosque_2 [Yellow] 129 points - 0.96147606
Citricos_2 [Green] 176 points and Bosque_2 [Yellow] 129 points - 1.95525485
Citricos_2 [Green] 176 points and Bosque_1 [Blue] 135 points - 1.95657120
Caña_M1 [Green] 164 points and Bosque_1 [Blue] 135 points - 1.99564005
Caña_M1 [Green] 164 points and Bosque_2 [Yellow] 129 points - 1.99581522
Caña_M1 [Green] 164 points and Citricos_2 [Green] 176 points - 1.99891084

```

Ilustración 39: Resultados del análisis de separabilidad de ROI

Al conjunto de imágenes CSK, se le aplica este clasificador, ajustando los parámetros de coeficientes angulares máximos, sobre las firmas temporales obtenidas, recursivamente hasta no detectar mejorías en los resultados obtenidos.

En la Tabla 6, se observan los valores enunciados para tal fin. Para la evaluación de los resultados se seleccionó solo el área clasificada de caña de azúcar con datos de campo para contrastar. Al resultado de la clasificación se le aplica un filtro de mayoría de una ventana de 7 x 7, antes de la realización de la evaluación por matriz de confusión.

Tabla 6: Coeficientes aplicados a las firmas temporales en dB

coeficientes angulares máximos (radianes)	
Caña de azúcar	0.155
Cítricos	0.105
Bosques	0.120

4.6.3.3 ISODATA

Es un método de clasificación no supervisado, sus iniciales responden a las siguientes palabras “*Iterative Self-Organizing Data Analysis Technique*”. El clasificador genera una distribución inicial de los datos en función del espacio de datos disponible, posteriormente se reclasifica la distribución inicial en función del número de clases elegidas por el analista, utilizando técnicas de distancia mínima. Cada iteración recalcula las medias y reclasifica los píxeles con respecto a las nuevas medias (Harris Geospatial Solution, 2013). El proceso iterativo dependerá de los valores de umbral para interrumpir las iteraciones y la cantidad máxima de iteraciones. La potencia de este clasificador es determinar agrupaciones de píxeles que tienen comportamiento similar en el espacio de las características.

No es necesario un estricto conocimiento del área de estudio, ya que la definición de áreas temáticas es post clasificación. Para la evaluación de los resultados se trabajó con el área clasificada de caña de azúcar que es en la cual se cuentan

con datos de campo para contrastar. Al resultado de la clasificación se le aplica un filtro de mayoría de una ventana de 7 x 7, antes de la realización de la evaluación por matriz de confusión.

En la ilustración 40, se representa esquemáticamente la metodología de este clasificador no supervisado.

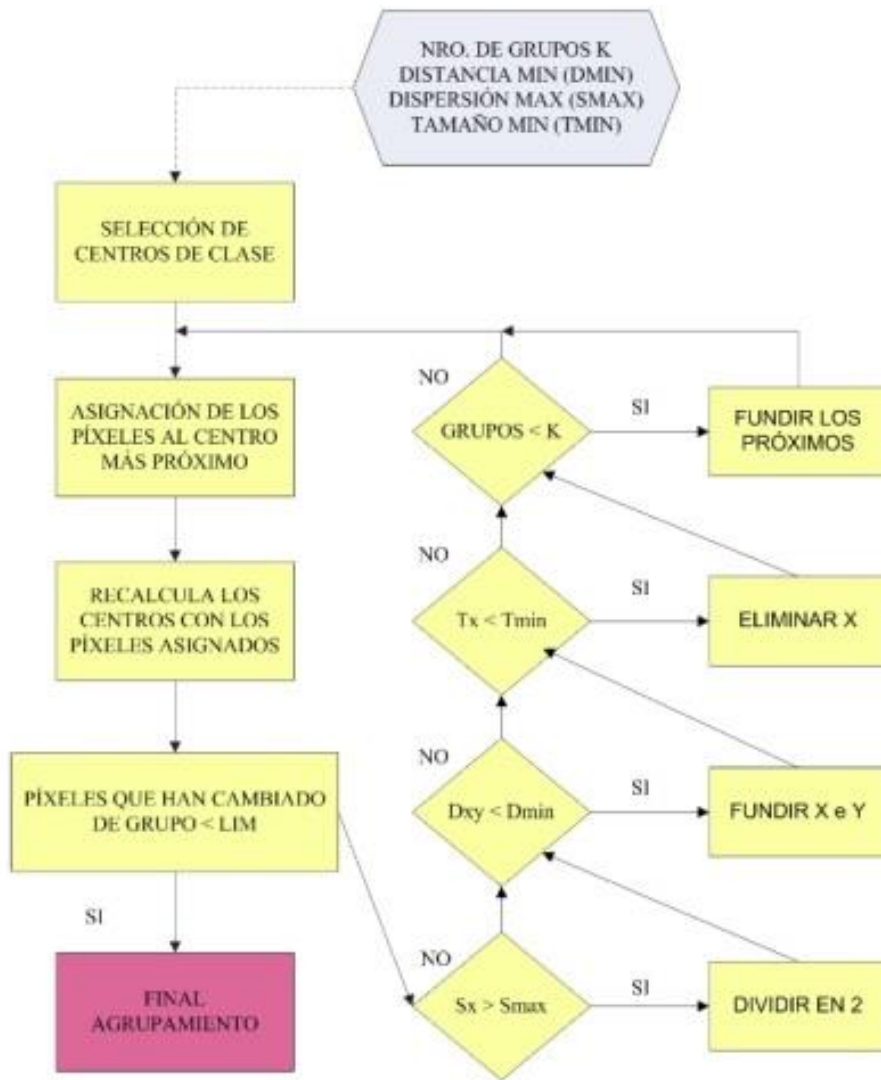


Ilustración 40: Síntesis metodológica del algoritmo ISODATA, elaborado por (Edrosa, 2011)

Al dataset de imágenes CSK, se le impone este clasificador, ajustando los parámetros del algoritmo, recursivamente hasta no detectar mejorías en los resultados obtenidos, en la Tabla 7, se observan los valores que finalmente se utilizan para tal fin.

Tabla 7: Parámetros ajustados para ISODATA

Número de clases	10 a 15
Máximo de iteraciones	100
Umbral de cambio	2%
Número mínimo de píxeles por clase	20
Desviación estándar máxima por clase	4
Distancia mínima entre medias de clases	0.5

4.6.3.4 K-means

En términos generales el método se basa en ir determinando las medias de las clases elegidas, posteriormente y de forma iterativa los píxeles son insertados en las clases más cercanas a esa media utilizando las técnicas de mínima distancia (Gimenez, 2010), como se observa en los agrupamientos generados por el clasificador en la ilustración 41. Es un método de agrupación de casos que se basa en las distancias existentes entre ellos en un conjunto de variables. El algoritmo es sencillo y eficiente. Además, procesa los patrones secuencialmente. Todos los píxeles se clasifican en la clase más cercana a menos que se especifique una desviación estándar o umbral de distancia, en cuyo caso algunos píxeles pueden no estar clasificados si no cumplen con los criterios seleccionados (Harris Geospatial Solution, 2013).




Ilustración 41: Patrones de agrupamiento en algoritmo K-means

Al conjunto de imágenes CSK, se le impone este clasificador, ajustando los parámetros del algoritmo, recursivamente hasta no detectar mejorías en los resultados obtenidos, en la Tabla 8, se observan los valores que finalmente se utilizan para tal fin. Para la evaluación de los resultados se trabajara con el área clasificada de caña de azúcar que se cuenta con datos de campo para contrastar. Al resultado de la clasificación se le aplica un filtro de mayoría de una ventana de 7 x 7, antes de la realización de la evaluación por matriz de confusión.

Tabla 8: Parámetros ajustados para K-means

Número de clases	10
Máximo de iteraciones	100
Umbral de cambio	5%
Desviación estándar máxima desde la media	10

Capítulo Cinco

Resultados

5.1 Comparación de datos ópticos y SAR

La difícil interpretación de la señal SAR, lleva asociada una compleja interacción de la retrodispersión entre la vegetación y el suelo. Factores propios del sistema SAR, como la frecuencia, la polarización y el ángulo de incidencia del haz y condiciones del blanco como la humedad del suelo, condiciones del cultivo y las precipitaciones, determinarán la profundidad de penetración como así también el comportamiento de la señal SAR en el tiempo. En el caso de los datos de campo de la zona de estudio secundaria resulto interesante la correlación entre datos de NDVI tomados en campo y los valores de retrodispersión de Sentinel 1 (Notarnicola et al., 2017). Esto motivó inicialmente a realizar la comparación entre la respuesta SAR de Cosmo SkyMed y el índice NDVI generado a partir de las imágenes Landsat 8, en la zona de estudio principal en Tucumán. Adicionalmente a la complejidad inicialmente descrita, este paralelismo entre la respuesta óptica y SAR se vio dificultada con el hecho de que las fechas de adquisición de las imágenes de los diferentes sensores no coincidían en el tiempo. Esta brecha entre las imágenes ópticas e imágenes SAR, dificulta enormemente la interpretación sumado a largos periodos en donde no había imágenes disponibles.

Sobre el conjunto de imágenes ópticas y SAR se obtienen ROI como fue descrito en el punto 4.6.2 del capítulo anterior. Finalmente, en la ilustración 42 se observa la respuesta de 11 muestras de caña de azúcar en dB sobre las imágenes SAR, mientras que en la ilustración 43, se exhibe el comportamiento de las mismas muestras en función a la respuesta de las imágenes en NDVI.

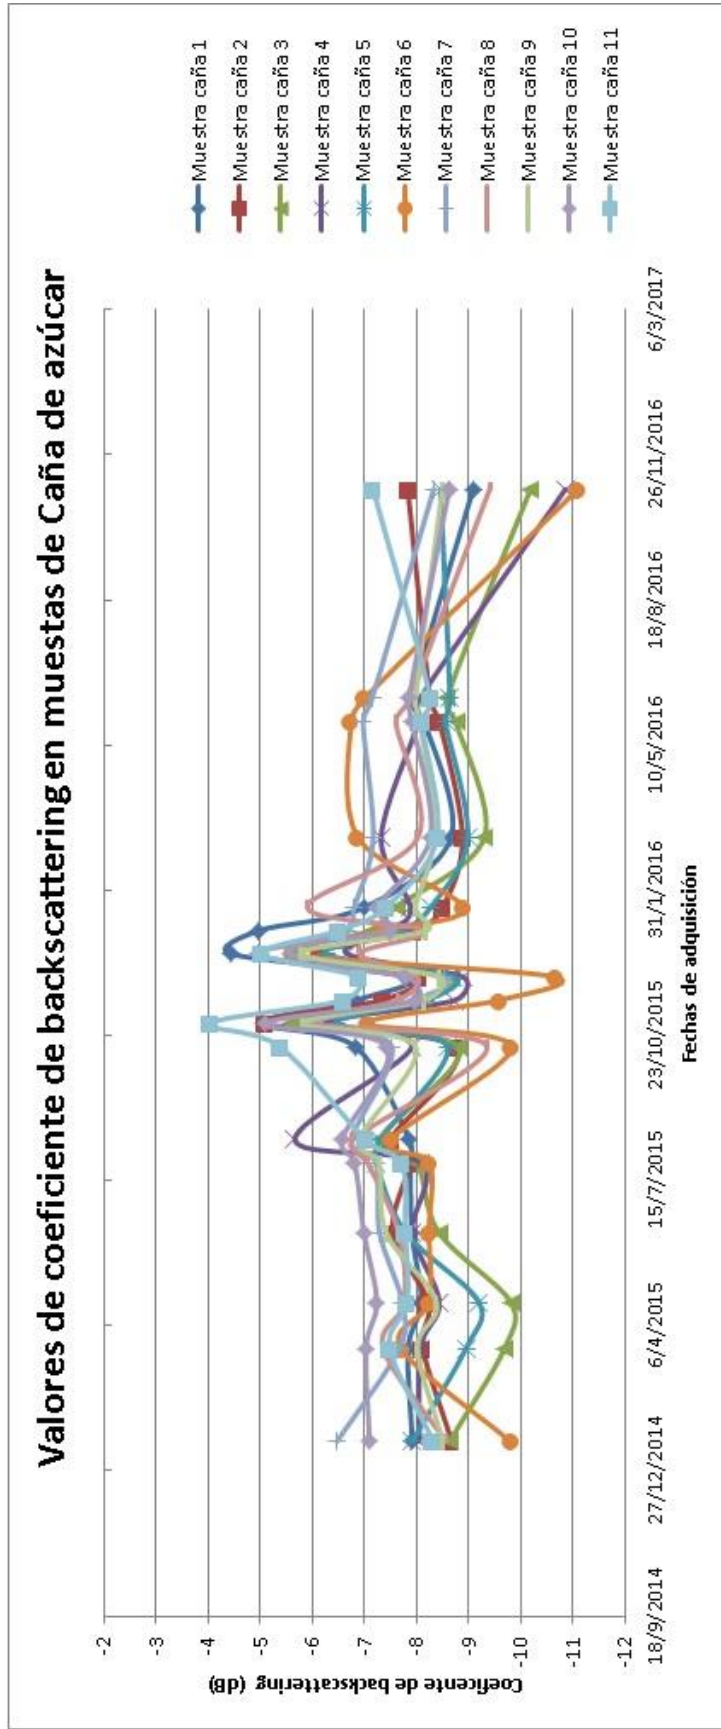


Ilustración 42: Valores en dB, obtenidas sobre el conjunto de imágenes CSK polarización HH, en muestras de caña de azúcar.




Ilustración 43: Valores en NDVI obtenidos en sobre el conjunto de imágenes Landsat 8, en muestras de caña de azúcar

Los valores del coeficiente de retrodispersión obtenidos se concentran alrededor de los -7 y -9 dB, estos valores son un resultado razonable y se asocian a la respuesta propia de esta cobertura (Caña de Azúcar) en la polarización disponible HH de la banda X (Paradis et al., 2010), mientras que las variaciones intermedias con cimas y valles podrían ser atribuidas a eventos fenológicos, como la cosecha, o a diferentes contribuciones por un aumento en la humedad del suelo, precipitaciones o agua libre sobre la estructura foliar en la caña de azúcar; descartando el aumento de la señal por acción de la rugosidad superficial del suelo probablemente debido a la baja sensibilidad de la banda X a la rugosidad de la superficie (Baghdadi, Boyer, Todoroff, El Hajj, & Bégué, 2009).

Si bien algunos estudios muestran una correlación entre la respuesta SAR y los parámetros del cultivo, la interpretación todavía no es definitiva. El coeficiente de retrodispersión sobre muestras de caña de azúcar en las imágenes Cosmo SkyMed en polarización HH presentó, en general, valores bajos cercanos a -8 dB mientras que en otros usos de suelo la respuesta es mayor, como se observa en la ilustración 38. Si bien las investigaciones (Baghdadi et al., 2009; Paradis et al., 2010), reconocen un aumento en la señal en periodos iniciales de crecimiento de la caña de azúcar, en este caso la falta de información biofísica de altura de la planta como así también la escasa o inadecuada de la cobertura temporal en dichos periodos, no permiten aseverar dicha respuesta.

Al observar los valores de NDVI en el tiempo la respuesta es más clara y conocida, se diferencia el comportamiento de la vegetación en el tiempo y se asocian las cimas de la curva del NDVI al máximo del Índice de Área Foliar y momentos en que la vegetación está vigorosa, en cambio, los valles al momento posterior a la cosecha donde la componente del suelo se expresa mayoritariamente sobre un pixel.

En la ilustración 44, de manera exploratoria se combina la media de las muestras de la respuesta en dB del coeficiente de retrodispersión con la correspondiente a la media de las muestras de la respuesta del NDVI.

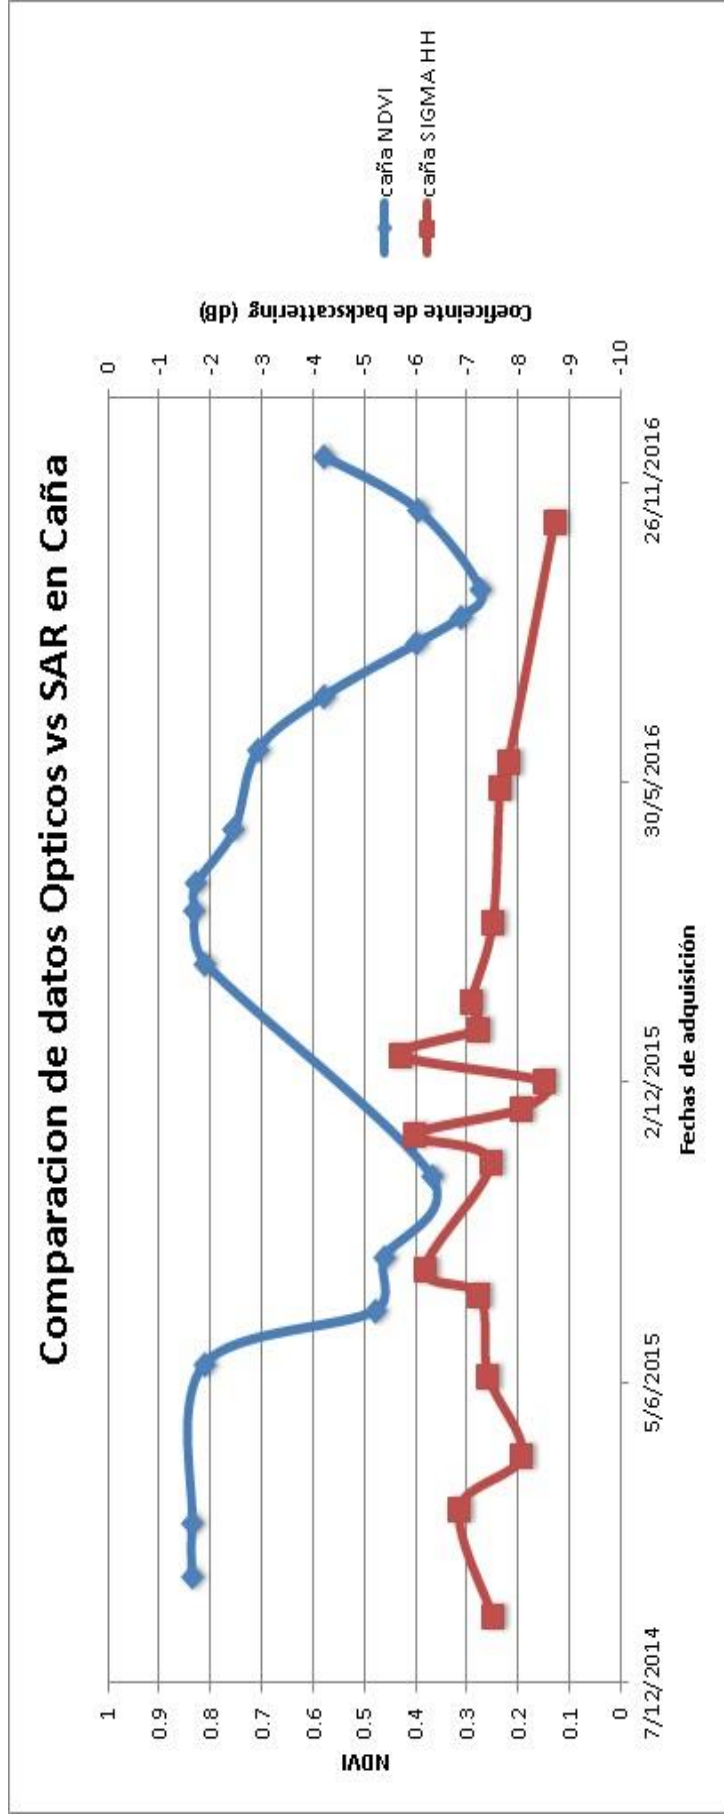


Ilustración 44: Comparación de los valores medios del conjunto de muestras de los datos SAR y datos ópticos

Se puede observar visualmente el conjunto de los datos analizados individualmente, como es la respuesta de los sensores ópticos, a través del uso del NDVI y la respuesta SAR, y la posible relación de estos con el comportamiento fenológico del cultivo de la caña de azúcar, para consolidar la potencialidad del uso de la información SAR en aquellas oportunidades en que la información óptica no está disponible.

El último análisis exploratorio realizado, se originó como alternativa para intentar explicar los mayores valores dentro de la respuesta SAR, y consistió en correlacionar las precipitaciones de la zona de estudio con los valores en dB de las imágenes SAR, y cómo estas pueden afectar el coeficiente de retrodispersión de la caña de azúcar de acuerdo a su momento e intensidad. Solo fue posible contar con datos de una estación meteorológica del INTA, en Estación Experimental de la localidad de Famailla, Tucumán (Sistema de Información y Gestión Agrometeorológico INTA, 2017), asociando el evento puntual como es la precipitación, sobre un área, transformándose en la principal limitación del análisis. En la ilustración 45, se puede observar dicho análisis.




Ilustración 45: Valores en dB de muestras caña de azúcar contrapuesto con las precipitaciones de la EE INTA Famailla

5.2 Clasificaciones

Se presentarán los resultados para la determinación del área sembrada con caña de azúcar, en la región de estudio de la Provincia de Tucumán, Argentina analizada y evaluada comparativamente entre los clasificadores no supervisados (ISODATA y K-Means) y el clasificador supervisado SAM. Posteriormente se analizarán los resultados del uso del clasificador de árbol de decisión para la determinación del momento de cosecha en caña de azúcar en la Provincia de Tucumán, Argentina y para la determinación del momento de corte e inicio de la estación de crecimiento en pastizales naturales con información SAR en la región de estudio de la Provincia de Bolzano, Italia.

5.2.1 Áreas Sembradas con caña de azúcar

Se exponen los resultados de las clasificaciones no supervisadas y supervisadas, en términos de precisión general, y el índice Kappa (este último indica la proporción de exactitud sin tener en cuenta los aciertos por azar), en el Anexo 4, se exponen las imágenes correspondientes a las clasificaciones. Posteriormente se describe en función de estos resultados la superficie sembrada con caña de azúcar que se puede determinar con cada clasificador. Como se observa en la ilustración 46, los resultados alcanzados en precisión general con el apilamiento de 17 imágenes SAR, es similar para los tres clasificadores, con valores cercanos al 80%. En cuanto a los clasificadores no supervisados, ISODATA alcanza un 79.13% de precisión general, así mismo K-means un 78.93%, mientras que el Spectral Angle Mapper (clasificador supervisado) resulta el de menor valor alcanzado con un 61.25% de precisión general.




Ilustración 46: Precisión general de las clasificaciones realizadas

Comparar el índice Kappa de los clasificadores evaluados, sirve como medida de concordancia de la clasificación sin tener en cuenta los aciertos al azar, obteniéndose los siguientes resultados, como se muestra en la ilustración 47: para el clasificador ISODATA el índice Kappa fue de 0.6579, para el clasificador K-means de 0.6496 y finalmente para el clasificador Spectral Angle Mapper de 0.4196, considerados como valores “*buenos*” en el caso de los primeros dos y “*razonables*” para el último, según (Monserud, 1990).




Ilustración 47: Valores del índice Kappa para cada clasificador evaluado

Una vez evaluados los clasificadores se calcula el área sembrada con caña de azúcar, a partir de la cantidad de píxeles clasificados por el tamaño del píxel, obteniéndose los siguientes resultados, expresados en la ilustración 48.




Ilustración 48: Área Clasificada y error de comisión de la clasificación en caña de azúcar

De alguna manera la determinación del área sembrada desenmascara los errores que puedan ocultarse en el valor de precisión general, determinando a partir de la superficie en hectáreas bien clasificadas, los errores cometidos por comisión, esto es aquellos píxeles que se incluyeron en una determinada categoría, perteneciendo realmente a otra (Chuvieco Salinero, 2006). Se puede observar y corroborar a partir de la Tabla 9, la exactitud del usuario y del productor que está íntimamente relacionada con el error de omisión y comisión respectivamente e inferir a través de esta o acudiendo al Anexo 5, que los errores por comisión son mayores en el clasificador ISODATA con un 24.53%, en el caso de K-means un 16.05% y en el clasificador SAM el error por comisión desciende a un 11.19%.

Tabla 9: Porcentajes de exactitud de usuario y productor

Clasificador	Exactitud	
	Usuario	Productor
ISODATA	75%	84%
K-medias	84%	72%
SAM	89%	58%

5.2.2 Mapa de Cosecha en caña de azúcar

El desarrollo de mapas de cosecha en el cultivo de caña de azúcar, obedece a la posibilidad de utilizar un índice espectral derivado de imágenes ópticas, en este caso el NDVI, para la determinación del momento de cosecha en los lotes implantados que cumplan con los requisitos del procedimiento realizado.

En la ilustración 49, se visualiza mediante gráficos de caja la distribución de un conjunto de datos, tomados sobre ROI de tres lotes de caña de azúcar diferentes, cosechados en distintas fechas, como fue explicado en el punto del capítulo anterior 4.6.3.1, los scripts utilizados para la realización de los mismos se adjuntan en el Anexo 2.

Momento de cosecha en funcion de la caída del NDVI

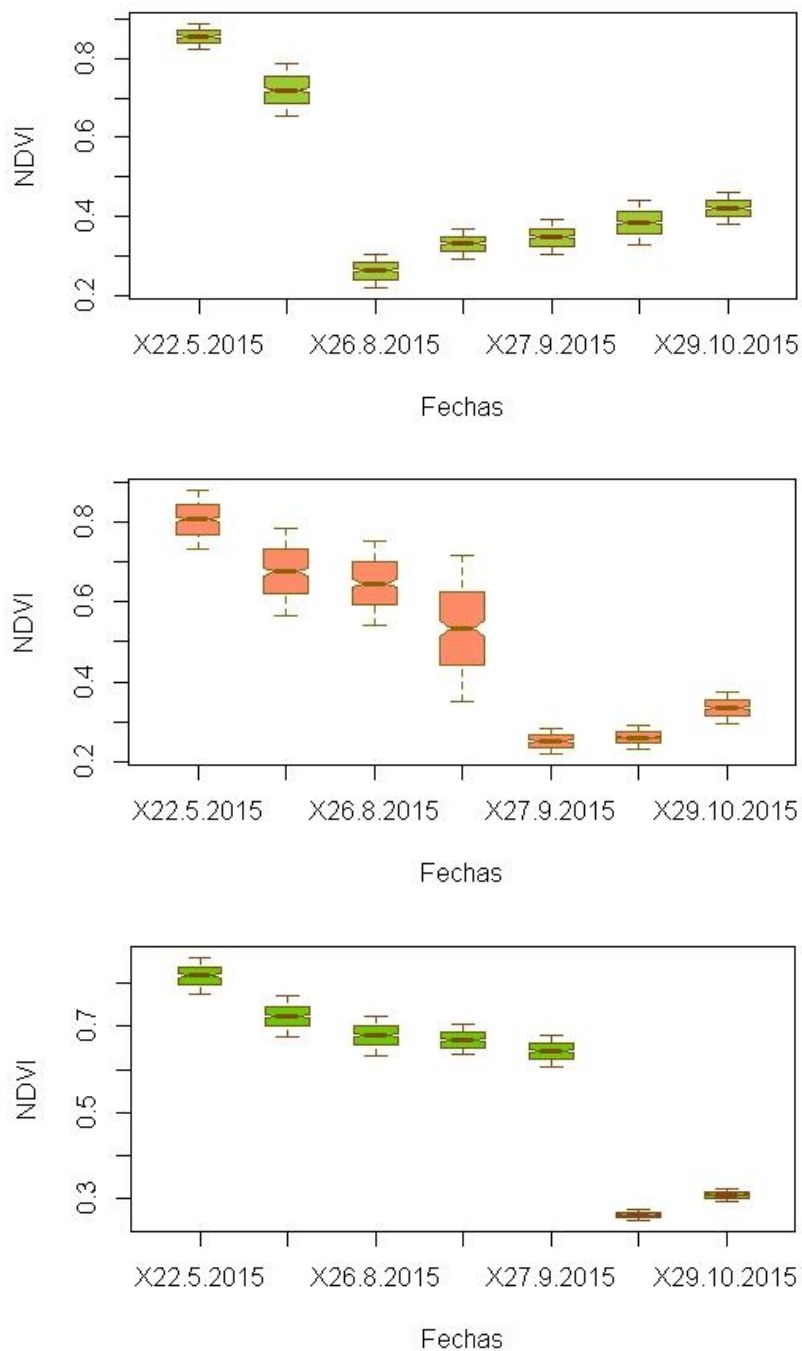


Ilustración 49: Caída del NDVI en diferentes fechas

Este primer análisis demuestra la diferencia notable entre la distribución de los datos para aquellas fechas entre las que se produce la cosecha de caña de azúcar.

El resultado del siguiente procedimiento observado en la ilustración 50, culmina con la generación de un mapa, generado metodológicamente a partir de imágenes ópticas, utilizando las bandas de Landsat 8 que intervienen en la generación del NDVI, al cual inicialmente se le realiza el filtrado de nubes, seguidamente se genera un nuevo apilamiento con las imágenes compuestas que representan el decaimiento de NDVI relacionado con en el periodo en el que se cosecha la caña de azúcar, determinando finalmente, a través del uso del árbol de decisión para clasificar temporalmente cuando ocurre esta caída del valor de NDVI, en el área de estudio.



Ilustración 50: Procedimiento para realizar el mapa de cosecha de caña de azúcar

En la ilustración 51, finalmente se expresa en un mapa, el producto de este procedimiento implementado con árbol de decisión y operaciones matemáticas en el software ENVI, en el Anexo 6 se puede observar otro mapa realizado para la cosecha del año 2016.

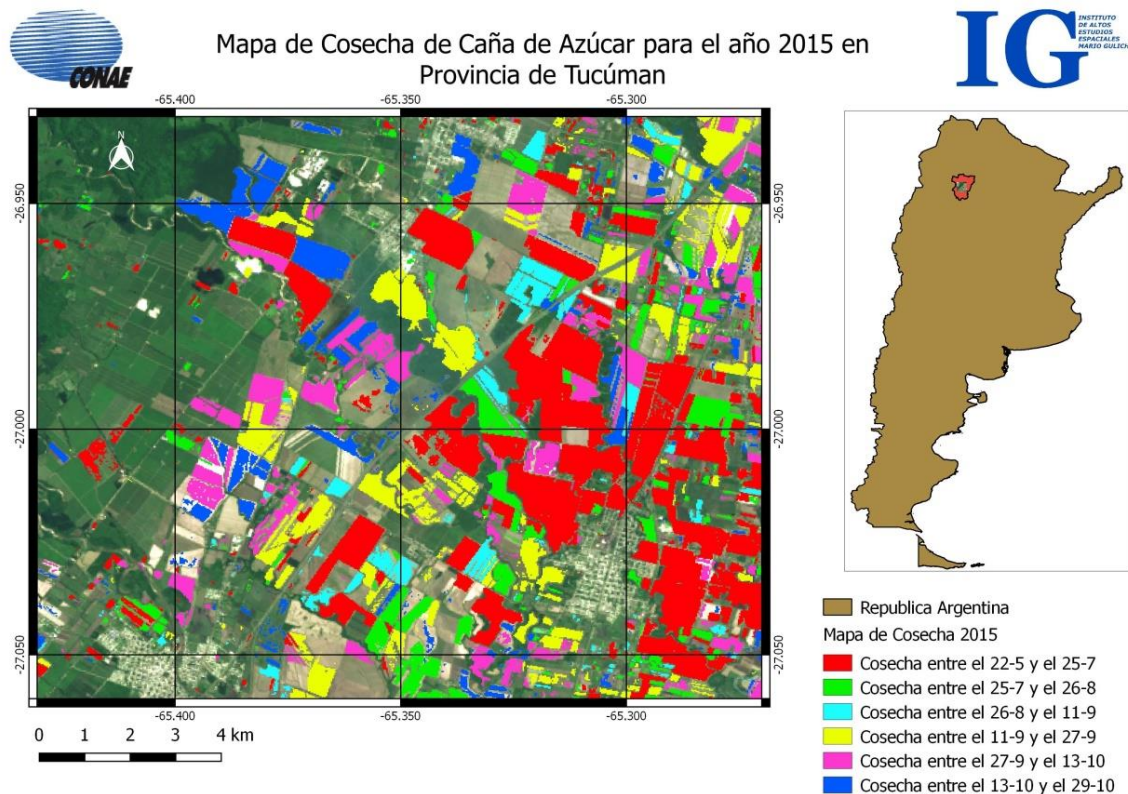


Ilustración 51: Mapa de Cosecha en caña de azúcar realizado con árbol de decisión

En cuanto a la validación del mapa de cosecha, la dificultad surge con los datos de “verdad de campo” que tenemos a disposición, estos no representan el momento de cosecha de los lotes de caña de azúcar sino simplemente la superficie ocupada por el cultivo, sin embargo se optó por analizar la precisión general de la clasificación, a través de una unión de todas las fechas detectadas (Merge) para recién allí poder compararlo con una serie de puntos generados aleatoriamente en la capa de datos de campo y transformados en ROI (Ver Anexo 7). Los resultados de este procedimiento fueron muy satisfactorios pero solo analizan la cobertura bajo análisis y alcanzaron un 95% de precisión general en la clasificación.

5.2.3 Mapa de Corte en Pastizales Naturales

En cuanto al caso de los pastizales naturales en la Provincia de Bolzano, Italia, el procedimiento para establecer el momento de corte (cosecha) de los pastizales, fue similar al utilizado en la caña de azúcar con diferencias en cuanto a que se aplicó el algoritmo de clasificación de árbol de decisión pero con imágenes SAR. Los resultados de este punto y los de 5.2.4, fueron expuestos en el congreso MultiTemp 2017 organizado en Brujas, Bélgica del 27 al 29 de Junio de 2017, como parte de una presentación del monitoreo de cultivos de montaña (Notarnicola et al., 2017).

La temporalidad de imágenes SAR (Sentinel 1) disponibles permiten disminuir las brechas entre imágenes contiguas, facilitando la interpretación fenológica en el tiempo de los pastizales naturales. En banda C, la respuesta a las características del suelo se ve limitada en polarizaciones VV y VH que en contraposición están fuertemente dominadas por las características de la vegetación según (Pasolli et al., 2014).

Las mediciones ópticas y SAR siguen una dinámica similar y la disminución de la señal de VH en el momento del corte está bien relacionada con la disminución de las señales de NDVI (Notarnicola et al., 2017). La discrepancia en las fechas obtenidas por medio del mapa y en las que se produce el corte del pastizal puede atribuirse a varios factores. El tiempo de adquisición de SAR es de alrededor de 12 días en 2015, por lo que el evento de corte se puede perder o que sea difícil de detectar en este intervalo. Además, la señal VH que representa un área, puede tener campos con diferente tiempo de corte.

Momento de cosecha en función de la caída de dB

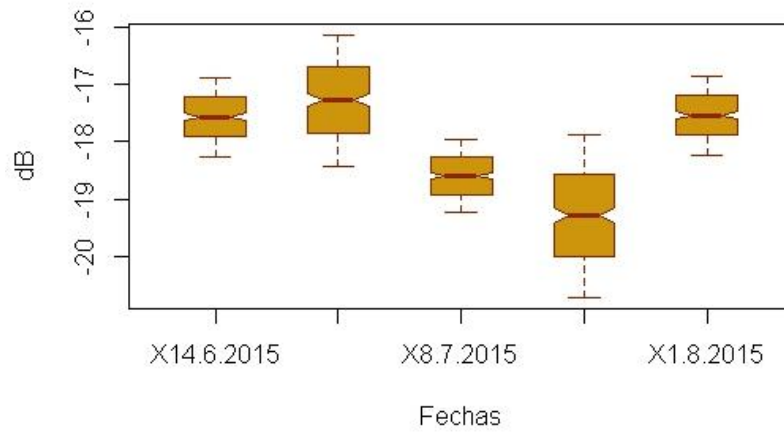


Ilustración 52: Caída de dB en asociado al corte de pastizales

En la ilustración precedente, se observa la distribución del conjunto de datos, con gráficos de caja sobre un área circundante a la estación Domef 1500. En la ilustración 53, en cambio, se explica el procedimiento realizado para la obtención de esta metodología.



Ilustración 53: Procedimiento para realizar el mapa de corte en Pastizales naturales

Si bien este procedimiento se desprende del análisis de las imágenes ópticas anteriormente realizado, la polarización VH analizada, tiene la característica de presentar una buena dinámica entre la respuesta óptica y radar para que sea posible generar el producto, caso contrario corresponde a lo analizado en las polarizaciones HH de la banda X en el punto 5.1. Inicialmente, se recorta la serie de imágenes disponibles a aquellas en las que se tiene un indicio que ocurrirá el corte de los pastizales. Posteriormente se aplica una máscara que filtra aquellos valores de pixeles mayores a -16 dB que se asocian al máximo valor de coeficiente de retrodispersión que puede asumir este uso del suelo y lo separa del resto de las coberturas de la región. El siguiente paso es encontrar aquellos pixeles que entre dos fechas diferentes tienen una caída de más de 2 dB en el coeficiente de retrodispersión, diferencia que permite reconocer las parcelas

cortadas en el periodo de análisis con el clasificador de árbol de decisión. El resultado de este procedimiento se visualiza en el mapa expuesto en la ilustración 54. Las phenocam, instaladas en las estaciones meteorológicas Vimes 1500 y Domef 1500, proveen el registro visual para validar los mapas generados.

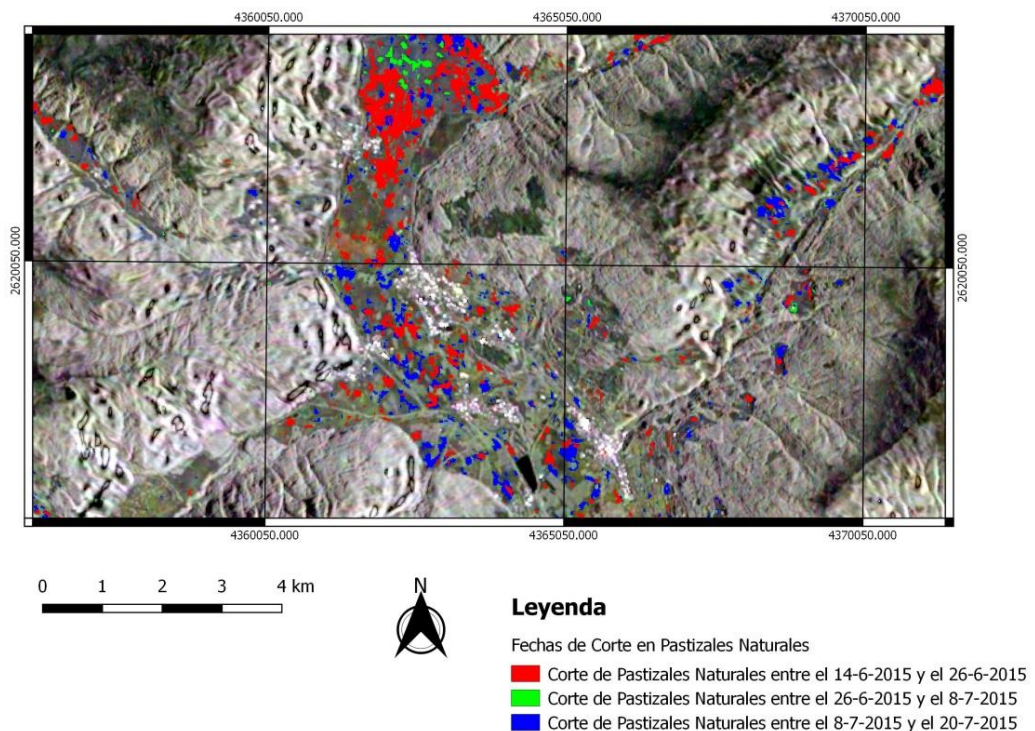


Ilustración 54: Mapa de fechas de corte en pastizales naturales, en zona cercana a la estación VIMES 1500

Sobre la estación VIMES 1500, se realiza la validación de estos resultados, mediante el registro fotográfico de las Phenocam. En cuanto al momento de corte sobre la ubicación geográfica de la estación, el producto detecta una corte entre el 26-6-2015 y el 8-7-2015 mientras que con la cámara efectivamente el corte ocurre entre el 29-6-2015 y el 3-7-2015, como se expresa en la presentación de (Notarnicola et al., 2017) y en la fuente de las estaciones meteorológicas mencionadas (<http://monalisasos.eurac.edu/sos/static/phenocam.html>). En la

ilustración 55, se observa el registro de la Phenocam para las fechas en que el producto detecta el corte, validando los resultados de la metodología aplicada.



Ilustración 55: Registro a campo en las fechas que satelitalmente se detecta el corte

5.2.4 Mapa de Inicio de temporada de crecimiento en Pastizales Naturales

Este producto es resultado del mismo procedimiento aplicado en el punto 5.2.3. Aquí el objetivo de la metodología, es determinar el momento de inicio de crecimiento de los pastizales naturales, fecha de interés para la programación de todas las actividades agronómicas, tanto las que son inherentes del productor como aquellas en las que intervienen los diferentes actores de la producción (el estado, empresas proveedoras de insumos, logística, etc.). En la siguiente ilustración 56 se desarrolla el procedimiento realizado para la obtención de esta metodología.

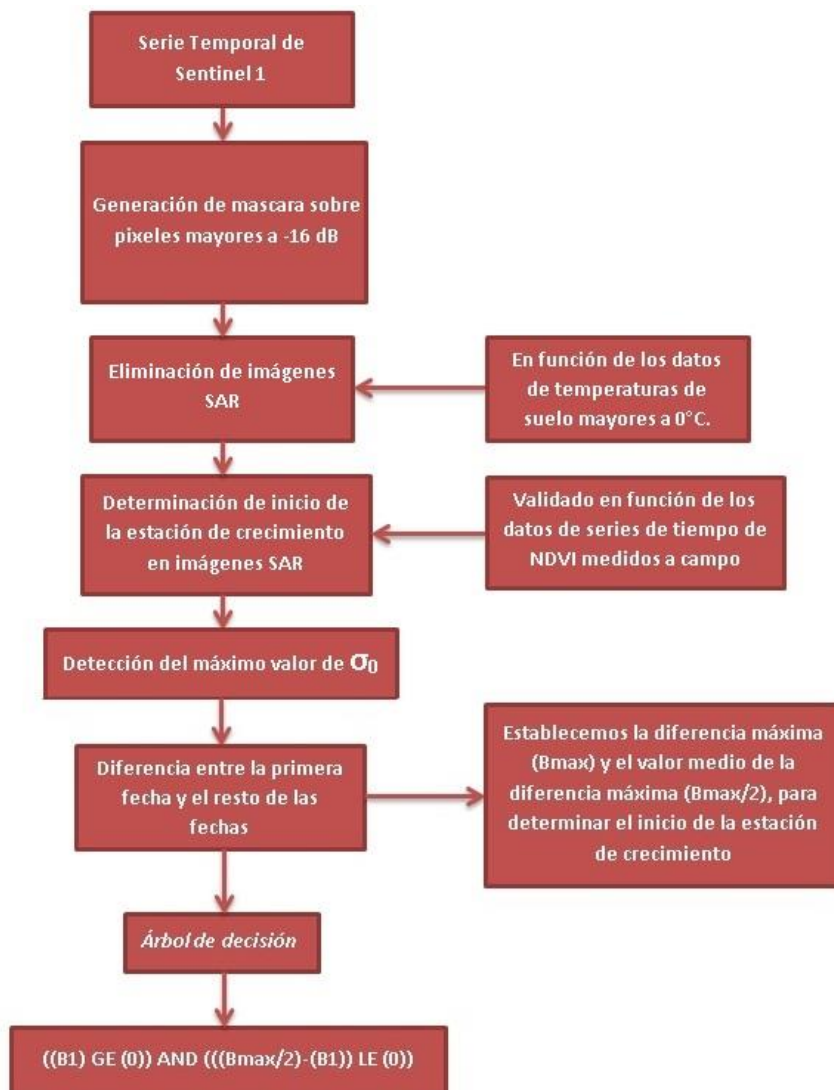


Ilustración 56: Procedimiento para realizar el mapa de inicio de crecimiento en pastizales naturales

La sustancial diferencia que existe entre el mapa de corte y el de inicio de crecimiento en pastizales naturales, en los Alpes centrales italianos, radica en que, inicialmente, se eliminan las fechas en función de datos de temperatura superficiales del suelo mayores a 0° centígrados (Notarnicola et al., 2017), considerada la temperatura por debajo de la cual no puede haber crecimiento en las plantas, esta información fue obtenida de datos de sensores de suelo en las estaciones meteorológicas consideradas. La fecha de inicio de estación de crecimiento se corrobora con los valores de NDVI medidos a campos mayores a 0.2 aproximadamente, esto puede comprobarse en la ilustración 57, donde también se aprecia con una marca de agua las imágenes CSK eliminadas por presentar temperaturas menores a la de crecimiento. Finalmente, se toma como criterio general que determina el inicio de la estación de crecimiento a partir de imágenes SAR, a aquellos pixeles que superen la mitad de la diferencia máxima, teniendo en cuenta la diferencia que existe entre la primera fecha (que supero el 0°C) y el resto de las fechas analizadas, como fue explicado en la ilustración 56.




Ilustración 57: Inicio de crecimiento en función de la temperatura de suelo y NDVI, extraído de (Notarnicola et al., 2017)

El producto que se obtiene utilizando esta metodología, se expone en la ilustración 58, en el cual se observan las diferentes zonas que inician el crecimiento para un mismo rango de fechas. Esto fue validado con el registro

fotográfico de la zona cercana a la estación Vimes 1500, en la cual se determinó el inicio de la estación de crecimiento entre el 16/4/2015 y el 20/5/2015 con las imágenes de la phenocam, la primera del 3/4/2015 antes del inicio del crecimiento, y las siguientes en las fechas que se detectó en el mapa el 15/4/2015 y el 27/4/2015, mientras que a través de la metodología utilizada con imágenes SAR se detecta el inicio del crecimiento sobre la estación meteorológica Vimes 1500 entre el 27/4/2015 y el 9/5/2015, como se observa en la ilustración 59.

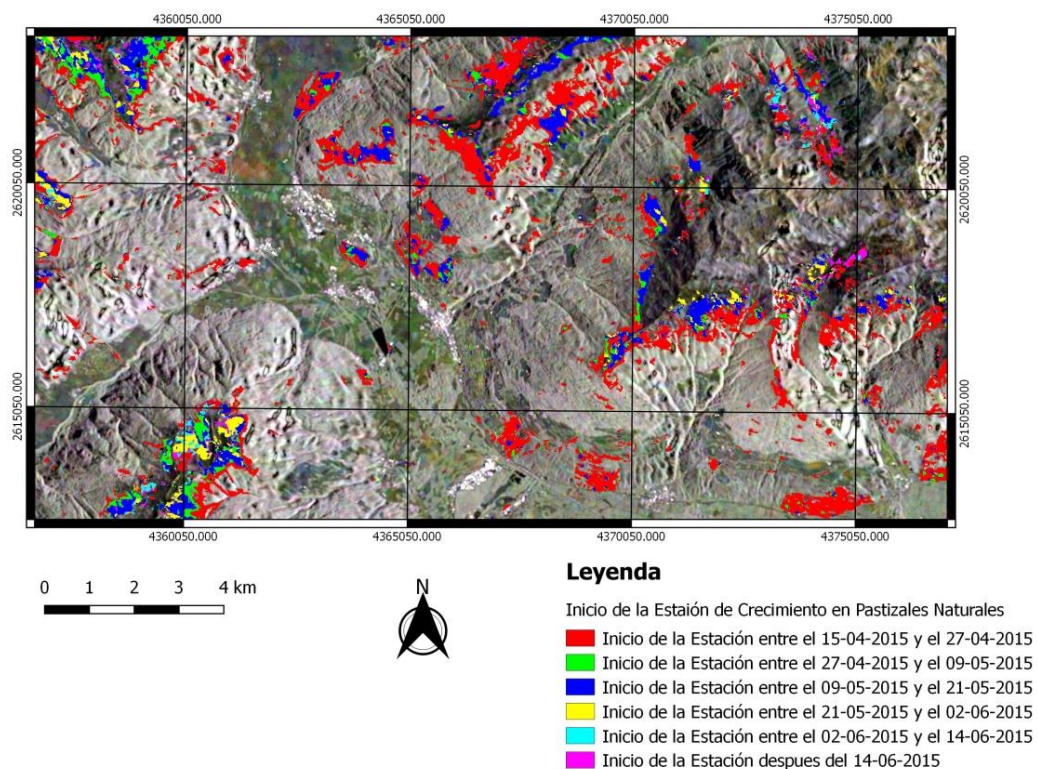


Ilustración 58: Mapa de fechas de inicio de crecimiento en pastizales naturales, en zona cercana a la estación VIMES 1500



Ilustración 59: Registro a campo en las fechas que satelitalmente se detecta el inicio de crecimiento

Capítulo Seis

Conclusiones

Una primera conclusión, haciendo énfasis en el uso del SAR para el estudio de las condiciones de vegetación y por la consecuente complejidad del mismo, es requerido un aumento en el número de experiencias de este tipo de investigación. En segundo lugar, y en cuanto a la temporalidad del conjunto de imágenes Cosmo SkyMed utilizadas, se puede decir que no fue adecuado para interpretar el comportamiento fenológico en el cultivo de la caña de azúcar. Como es sabida la interpretación del crecimiento es una condición dinámica en la que un valor en el tiempo está restringido a la interpretación en el tiempo anterior, por lo que se considera para trabajos futuros adecuar la separación o rango de tiempo entre imágenes para favorecer la interpretación de las mismas.

Otra conclusión es sugerir para mejorar el análisis, que son necesarios diversos parámetros de cultivo tales como la biomasa, ancho de las hojas, altura del cultivo, como se expresa en la experiencia (Bouman, 1991), como información de campo, para dar respuestas concluyentes en el comportamiento del cultivo de la caña de azúcar, bajo la situación analizada. No obstante, con la información de campo disponible, no ha sido menor la información exploratoria obtenida.

Respecto a la respuesta de las observaciones SAR en los cultivos podemos destacar que existe un problema generalizado en las estimaciones agrícolas en Banda X, expresada por (Bouman, 1991; Koppe et al., 2013; Paradis et al., 2010; Portnoi, 2017) como así también en estimaciones forestales (Kuntz et al., 2012; Sinha, Jeganathan, Sharma, & Nathawat, 2015) que se refiere a la saturación de la señal de retrodispersión, lo que dificulta aún más las interpretaciones biofísicas independientemente de la polarización utilizada, siendo inadecuada la banda X para tal fin. En cuanto a la polarización, se corroboró la existencia de una

dificultad inherente a la interacción de la vegetación con la polarización HH en Banda X (caña de azúcar) , mientras que la polarización VH en Banda C (pastizales naturales) fue adecuada para describir características de la vegetación, tal como fue citado en (Paradis et al., 2010). En este sentido, podemos inferir que la utilización de las futuras adquisiciones del SAOCOM (Banda L), podrán explorar otros parámetros de la vegetación debido a su profundidad de penetración. De esta manera, se espera que la observación en múltiples polarizaciones SAR favorezca la capacidad de observación, interpretación y clasificación de los cultivos. Para resumir es concluyente que la polarización HH no es la más adecuada para el análisis en caña de azúcar. Sin embargo, con el conjunto de imágenes analizadas fue posible su clasificación de manera correcta como se explica más adelante.

Resulta imperioso profundizar la relación que existe entre las precipitaciones y la contribución de la señal retrodispersada por parte del suelo en periodos iniciales de crecimiento. Al mejorar estos aspectos se podrá correlacionar de manera más adecuada la relación e interpretación entre los datos SAR y Ópticos. Estos últimos siguen demostrando su potencia en cuanto al análisis de las características de la vegetación siempre y cuando la cobertura nubosa sea mínima, permitiendo realizar productos de valor y fáciles de obtener como el mapa de cosecha en caña de azúcar.

En cuanto a la clasificación SAR, se destaca el uso de clasificadores no supervisados (tanto ISODATA como K-Means) con resultados aceptables (79% precisión general) teniendo en cuenta que la clasificación era temporal; mientras que el uso exploratorio del clasificador supervisado SAM en imágenes SAR, no alcanzó a igualar los niveles de los clasificadores no supervisados (61% precisión general), atribuyéndose esta mala performance a que fue diseñado para imágenes hiperespectrales. No obstante, este resultado se puede mejorar, como ya fue expresado, con la utilización de un rango temporal de separación entre las imágenes más adecuado.

Finalmente, en cuanto al uso del algoritmo de clasificación denominado “árbol de decisión”, se destaca su potencialidad para generar productos de fácil interpretación, que permiten analizar las diferentes etapas de desarrollo de los

cultivos y que, de esta manera, abren el camino a la posibilidad futura de automatizar su procesamiento y, así, obtener mapas que grafiquen la dinámica fenológica de los mismos con mayor fidelidad.

Anexo

Anexo 1: Tablas de datos de campo de la zona de estudio secundaria, en Bolzano, Italia

Estación Vimes 1500		
Fecha	Mean NDVI_Avg	Sigma VV (dB)
26/2/2015	-0.049	
27/2/2015	-0.058	
28/2/2015	-0.024	
1/3/2015	0.002	
2/3/2015	-0.098	
3/3/2015	0.006	
4/3/2015	0.046	
5/3/2015	-0.007	
6/3/2015	-0.001	
7/3/2015	0.163	
8/3/2015	0.18	
9/3/2015	0.191	
10/3/2015	0.18	
11/3/2015	0.175	
12/3/2015	0.179	
13/3/2015	0.178	
14/3/2015	0.175	
15/3/2015	0.168	
16/3/2015	-0.007	
17/3/2015	0.019	
18/3/2015	0.151	
19/3/2015	0.15	
20/3/2015	0.152	
21/3/2015	0.187	
22/3/2015	-0.164	
23/3/2015	-0.056	
24/3/2015	0.188	
25/3/2015	0.201	
26/3/2015	-0.058	

27/3/2015	-0.011	
28/3/2015	0.124	
29/3/2015	0.123	
30/3/2015	-0.333	
31/3/2015	-0.041	
1/4/2015	-0.365	
2/4/2015	-0.026	
3/4/2015	0.226	
4/4/2015	0.25	
5/4/2015	0.172	
6/4/2015	0.212	
7/4/2015	0.205	
8/4/2015	0.198	
9/4/2015	0.197	
10/4/2015	0.202	
11/4/2015	0.212	
12/4/2015	0.212	
13/4/2015	0.22	
14/4/2015	0.223	
15/4/2015	0.23	
16/4/2015	0.241	
17/4/2015	0.266	
18/4/2015	0.262	
19/4/2015	0.267	
20/4/2015	0.266	
21/4/2015	0.272	
22/4/2015	0.277	
23/4/2015	0.282	
24/4/2015	0.292	
25/4/2015	0.314	
26/4/2015	0.366	
27/4/2015	0.433	
28/4/2015	0.349	
29/4/2015	0.344	
30/4/2015	0.426	
1/5/2015	0.539	
2/5/2015	0.383	
3/5/2015	0.479	
4/5/2015	0.533	
5/5/2015	0.473	
6/5/2015	0.586	
7/5/2015	0.492	
8/5/2015	0.537	
9/5/2015	0.539	
10/5/2015	0.531	

11/5/2015	0.539	
12/5/2015	0.551	
13/5/2015	0.56	
14/5/2015	0.577	
15/5/2015	0.704	
16/5/2015	0.569	
17/5/2015	0.58	
18/5/2015	0.587	
19/5/2015	0.621	
20/5/2015	0.767	
21/5/2015	0.617	
22/5/2015	0.607	
23/5/2015	0.615	
24/5/2015	0.603	
25/5/2015	0.599	
26/5/2015	0.604	
27/5/2015	0.596	
28/5/2015	0.585	
29/5/2015	0.598	
30/5/2015	0.597	
31/5/2015	0.616	
1/6/2015	0.608	
2/6/2015	0.617	
3/6/2015	0.633	
4/6/2015	0.632	
5/6/2015	0.63	
6/6/2015	0.632	
7/6/2015	0.633	
8/6/2015	0.641	
9/6/2015	0.653	
10/6/2015	0.631	
11/6/2015	0.639	
12/6/2015	0.629	
13/6/2015	0.627	
14/6/2015	0.691	
15/6/2015	0.657	
16/6/2015	0.651	
17/6/2015	0.621	
18/6/2015	0.624	
19/6/2015	0.623	
20/6/2015	0.624	
21/6/2015	0.625	
22/6/2015	0.626	
23/6/2015	0.628	
24/6/2015	0.621	

25/6/2015	0.62	
26/6/2015	0.627	
27/6/2015	0.627	
28/6/2015	0.626	
29/6/2015	0.624	
30/6/2015	0.628	
1/7/2015	0.634	
2/7/2015	0.782	
3/7/2015	0.656	
4/7/2015	0.652	
5/7/2015	0.648	
6/7/2015	0.653	
7/7/2015	0.643	
8/7/2015	0.61	
9/7/2015	0.574	
10/7/2015	0.482	
11/7/2015	0.377	
12/7/2015	0.392	
13/7/2015	0.378	
14/7/2015	0.391	
15/7/2015	0.386	
16/7/2015	0.393	
17/7/2015	0.39	
18/7/2015	0.407	
19/7/2015	0.419	
20/7/2015	0.428	
21/7/2015	0.462	
22/7/2015	0.495	
23/7/2015	0.516	
24/7/2015	0.541	
25/7/2015	0.549	
26/7/2015	0.541	
27/7/2015	0.55	
6/8/2015	0.648	
7/8/2015	0.668	
8/8/2015	0.666	
9/8/2015	0.676	
10/8/2015	0.656	
11/8/2015	0.656	
12/8/2015	0.661	
13/8/2015	0.66	
14/8/2015	0.67	
15/8/2015	0.746	
16/8/2015	0.677	
17/8/2015	0.684	

18/8/2015	0.659	
19/8/2015	0.669	
20/8/2015	0.656	
21/8/2015	0.65	
22/8/2015	0.652	
23/8/2015	0.666	
24/8/2015	0.669	
25/8/2015	0.654	
26/8/2015	0.644	
27/8/2015	0.65	
28/8/2015	0.653	
29/8/2015	0.652	
30/8/2015	0.65	
31/8/2015	0.651	
1/9/2015	0.651	
2/9/2015	0.668	
3/9/2015	0.654	
4/9/2015	0.635	
5/9/2015	0.654	
6/9/2015	0.64	
7/9/2015	0.536	
8/9/2015	0.446	
9/9/2015	0.373	
10/9/2015	0.367	
11/9/2015	0.351	
12/9/2015	0.324	
13/9/2015	0.356	
14/9/2015	0.434	
15/9/2015	0.372	
16/9/2015	0.384	
17/9/2015	0.369	
18/9/2015	0.361	
19/9/2015	0.382	
20/9/2015	0.361	
21/9/2015	0.362	
22/9/2015	0.419	
23/9/2015	-0.06	
24/9/2015	0.414	
25/9/2015	0.373	
26/9/2015	0.376	
27/9/2015	0.379	
28/9/2015	0.379	
29/9/2015	0.38	
30/9/2015	0.377	
1/10/2015	0.411	

2/10/2015	0.445	
3/10/2015	0.423	
4/10/2015	0.439	
5/10/2015	0.337	
6/10/2015	0.344	
7/10/2015	0.444	
8/10/2015	0.434	
9/10/2015	0.301	
10/10/2015	0.315	
11/10/2015	0.308	
12/10/2015	0.281	
26/2/2015		-19.7759
10/3/2015		-20.360198
22/3/2015		-18.090079
3/4/2015		-18.152104
15/4/2015		-15.809223
27/4/2015		-17.798342
9/5/2015		-18.867383
21/5/2015		-18.927503
2/6/2015		
14/6/2015		-17.913327
26/6/2015		-16.635929
8/7/2015		-15.996983
20/7/2015		-18.766281
22/7/2015		-17.010543
1/8/2015		-17.850802
13/8/2015		-19.635266
25/8/2015		-19.766249
6/9/2015		-21.527176
18/9/2015		-20.50003
30/9/2015		-22.112468
12/10/2015		-22.862924

Estación Domef 1500		
Fecha	Mean NDVI_Avg	Sigma VV (dB)
13/2/2015	-0.16	
7/3/2015	-0.059	
8/3/2015	-0.061	
9/3/2015	-0.058	
10/3/2015	-0.057	
11/3/2015	-0.065	
12/3/2015	-0.033	
13/3/2015	0.019	

14/3/2015	0.1	
15/3/2015	0.15	
16/3/2015	0.007	
17/3/2015	0.205	
18/3/2015	0.311	
19/3/2015	0.318	
20/3/2015	0.314	
21/3/2015	0.289	
22/3/2015	-0.076	
23/3/2015	0.18	
24/3/2015	0.295	
25/3/2015	0.303	
26/3/2015	0.255	
27/3/2015	0.302	
28/3/2015	0.288	
29/3/2015	0.282	
30/3/2015	0.285	
31/3/2015	0.31	
1/4/2015	0.315	
2/4/2015	0.317	
3/4/2015	0.323	
4/4/2015	0.328	
5/4/2015	0.352	
6/4/2015	0.35	
7/4/2015	0.351	
8/4/2015	0.354	
9/4/2015	0.372	
10/4/2015	0.388	
11/4/2015	0.414	
12/4/2015	0.435	
13/4/2015	0.467	
14/4/2015	0.489	
15/4/2015	0.51	
16/4/2015	0.546	
17/4/2015	0.591	
18/4/2015	0.591	
19/4/2015	0.583	
20/4/2015	0.592	
21/4/2015	0.6	
22/4/2015	0.614	
23/4/2015	0.632	
24/4/2015	0.647	
25/4/2015	0.667	
26/4/2015	0.683	
27/4/2015	0.695	

28/4/2015	0.707	
29/4/2015	0.701	
30/4/2015	0.715	
1/5/2015	0.731	
2/5/2015	0.73	
3/5/2015	0.739	
4/5/2015	0.769	
5/5/2015	0.759	
6/5/2015	0.758	
7/5/2015	0.765	
8/5/2015	0.763	
9/5/2015	0.759	
10/5/2015	0.764	
11/5/2015	0.767	
12/5/2015	0.757	
13/5/2015	0.741	
14/5/2015	0.766	
15/5/2015	0.8	
16/5/2015	0.756	
17/5/2015	0.774	
18/5/2015	0.769	
19/5/2015	0.761	
20/5/2015	0.801	
21/5/2015	0.771	
22/5/2015	0.762	
23/5/2015	0.815	
24/5/2015	0.84	
25/5/2015	0.768	
26/5/2015	0.754	
27/5/2015	0.772	
28/5/2015	0.767	
29/5/2015	0.769	
30/5/2015	0.757	
31/5/2015	0.752	
1/6/2015	0.757	
2/6/2015	0.767	
3/6/2015	0.755	
4/6/2015	0.762	
5/6/2015	0.771	
6/6/2015	0.76	
7/6/2015	0.764	
8/6/2015	0.74	
9/6/2015	0.721	
10/6/2015	0.726	
11/6/2015	0.71	

12/6/2015	0.727	
13/6/2015	0.714	
14/6/2015	0.721	
15/6/2015	0.689	
16/6/2015	0.689	
17/6/2015	0.699	
18/6/2015	0.686	
19/6/2015	0.686	
20/6/2015	0.688	
21/6/2015	0.682	
22/6/2015	0.671	
23/6/2015	0.674	
24/6/2015	0.678	
25/6/2015	0.674	
26/6/2015	0.684	
27/6/2015	0.673	
28/6/2015	0.678	
29/6/2015	0.515	
30/6/2015	0.462	
1/7/2015	0.436	
2/7/2015	0.416	
3/7/2015	0.411	
4/7/2015	0.42	
5/7/2015	0.432	
6/7/2015	0.457	
7/7/2015	0.494	
8/7/2015	0.545	
9/7/2015	0.557	
10/7/2015	0.577	
11/7/2015	0.612	
12/7/2015	0.638	
13/7/2015	0.666	
14/7/2015	0.68	
15/7/2015	0.697	
16/7/2015	0.707	
17/7/2015	0.714	
18/7/2015	0.731	
19/7/2015	0.739	
20/7/2015	0.747	
21/7/2015	0.751	
22/7/2015	0.731	
23/7/2015	0.763	
24/7/2015	0.312	
25/7/2015	0.34	
26/7/2015	0.756	

27/7/2015	0.491	
28/7/2015	0.761	
29/7/2015	0.757	
30/7/2015	0.765	
31/7/2015	0.769	
1/8/2015	0.752	
2/8/2015	0.769	
3/8/2015	0.778	
4/8/2015	0.778	
5/8/2015	0.777	
6/8/2015	0.776	
7/8/2015	0.775	
8/8/2015	0.763	
9/8/2015	0.777	
10/8/2015	0.779	
11/8/2015	0.781	
12/8/2015	0.779	
13/8/2015	0.778	
14/8/2015	0.754	
15/8/2015	0.755	
16/8/2015	0.766	
17/8/2015	0.735	
18/8/2015	0.742	
19/8/2015	0.744	
20/8/2015	0.76	
21/8/2015	0.767	
22/8/2015	0.766	
23/8/2015	0.741	
24/8/2015	0.737	
25/8/2015	0.747	
26/8/2015	0.764	
27/8/2015	0.768	
28/8/2015	0.768	
29/8/2015	0.77	
30/8/2015	0.77	
31/8/2015	0.765	
1/9/2015	0.759	
2/9/2015	0.227	
3/9/2015	0.256	
4/9/2015	0.373	
5/9/2015	0.742	
6/9/2015	0.748	
7/9/2015	0.743	
8/9/2015	0.589	
9/9/2015	0.544	

10/9/2015	0.518	
11/9/2015	0.521	
12/9/2015	0.51	
13/9/2015	0.527	
14/9/2015	0.533	
15/9/2015	0.554	
16/9/2015	0.566	
17/9/2015	0.592	
18/9/2015	0.603	
19/9/2015	0.249	
20/9/2015	0.816	
21/9/2015	0.83	
22/9/2015	0.602	
23/9/2015	-0.175	
24/9/2015	0.605	
25/9/2015	0.621	
26/9/2015	0.621	
27/9/2015	0.234	
28/9/2015	0.278	
29/9/2015	0.774	
30/9/2015	0.288	
1/10/2015	0.369	
2/10/2015	0.629	
3/10/2015	0.642	
4/10/2015	0.645	
5/10/2015	0.647	
6/10/2015	0.64	
7/10/2015	0.649	
8/10/2015	0.653	
9/10/2015	0.652	
10/10/2015	0.652	
11/10/2015	0.663	
12/10/2015	0.657	
26/2/2015		-18.868698
10/3/2015		-19.395055
22/3/2015		-18.153876
3/4/2015		-18.245701
15/4/2015		-17.492243
27/4/2015		-19.005092
9/5/2015		-17.584539
21/5/2015		-19.044902
2/6/2015		
14/6/2015		-18.530533
26/6/2015		-17.260677
8/7/2015		-17.520082

20/7/2015	-19.031517
20/7/2015	-16.766956
1/8/2015	-17.472729
13/8/2015	-18.250416
25/8/2015	-19.067682
6/9/2015	-19.71645
18/9/2015	-18.024616
30/9/2015	-20.906882
12/10/2015	-20.6268

Anexo 2: Scripts en R-studio

Box-plots de caña de azúcar

```
getwd()
setwd("D:/IMAGENES/Landsat8_Less_10cloud_SR/NDVI_STACK/MAPAS_DE_CAMBIO/
231-79_recorte_año2015/DATOS_para_graficas/")
box_plot_cosecha_ROI9<-read.table("Medias_ROI9_cosecha.txt", header=TRUE, sep = "\t")
boxplot(box_plot_cosecha_ROI9, main="Momento de cosecha en funcion de la caida del
NDVI", xlab = "Fechas", ylab = "NDVI",
        data="ToothGrowth", notch=TRUE, col="salmon1", border="darkgoldenrod4",
        boxwex=0.5)
box_plot_cosecha_ROI5<-read.table("Medias_ROI5_cosecha.txt", header=TRUE, sep = "\t")
boxplot(box_plot_cosecha_ROI5, main="Momento de cosecha en funcion de la caida del
NDVI", xlab = "Fechas", ylab = "NDVI",
        data="ToothGrowth", notch=TRUE, col="chartreuse3", border="chocolate4",
        boxwex=0.5)
box_plot_cosecha_ROI8<-read.table("Medias_ROI8_cosecha.txt", header=TRUE, sep = "\t")
boxplot(box_plot_cosecha_ROI8, main="Momento de cosecha en funcion de la caida del
NDVI", xlab = "Fechas", ylab = "NDVI",
        data="ToothGrowth", notch=TRUE, col="yellowgreen", border="chocolate4",
        boxwex=0.5)
```

Box-plot de Pastizales


```
getwd()
setwd("D:/CLAUDIA/Cosecha/Cosecha_Meadow/DATOS_graficos_r/")
box_plot_cosecha_meadow<-read.table("Prueba.txt", header=TRUE, sep = "\t")
boxplot(box_plot_cosecha_meadow, main="Momento de cosecha en funcion de la caida de
dB",
        xlab = "Fechas", ylab = "dB", data="ToothGrowth", notch=TRUE, col="darkgoldenrod3",
        border="orangered4", boxwex=0.5)
```

Anexo 3: Tablas de valores medios en la respuesta SAR y óptica sobre ROI de caña de azúcar


FECHAS	caña	
	NDVI	SIGMA HH (dB)
8/2/2015	0.836629	
12/3/2015	0.83604	
16/6/2015	0.811717	
18/7/2015	0.479477	
19/8/2015	0.461602	
6/10/2015	0.367979	
11/2/2016	0.80954	
14/3/2016	0.830616	
30/3/2016	0.827623	
1/5/2016	0.754431	
18/6/2016	0.707667	
20/7/2016	0.5802	
21/8/2016	0.397682	
6/9/2016	0.311211	
22/9/2016	0.273034	
9/11/2016	0.394647	
11/12/2016	0.578481	
16/1/2015		-7.500891
21/3/2015		-6.851849
22/4/2015		-8.070048
9/6/2015		-7.410081
27/7/2015		-7.245538
12/8/2015		-6.183964
15/10/2015		-7.457811
31/10/2015		-5.97609
16/11/2015		-8.070529
2/12/2015		-8.518409
18/12/2015		-5.70681
3/1/2016		-7.240985
19/1/2016		-7.090122
7/3/2016		-7.510164
26/5/2016		-7.645548
11/6/2016		-7.807095
2/11/2016		-8.712211

Anexo 4: Clasificaciones de la zona de estudio principal


Clasificación ISODATA, sobre el área de estudio con filtro de mayoría de una ventana de 7 x 7.



Clasificación K-means, sobre el área de estudio con filtro de mayoría de una ventana de 7 x 7.



Clasificación Spectral Angle Mapper, sobre el área de estudio con filtro de mayoría de una ventana de 7 x 7.



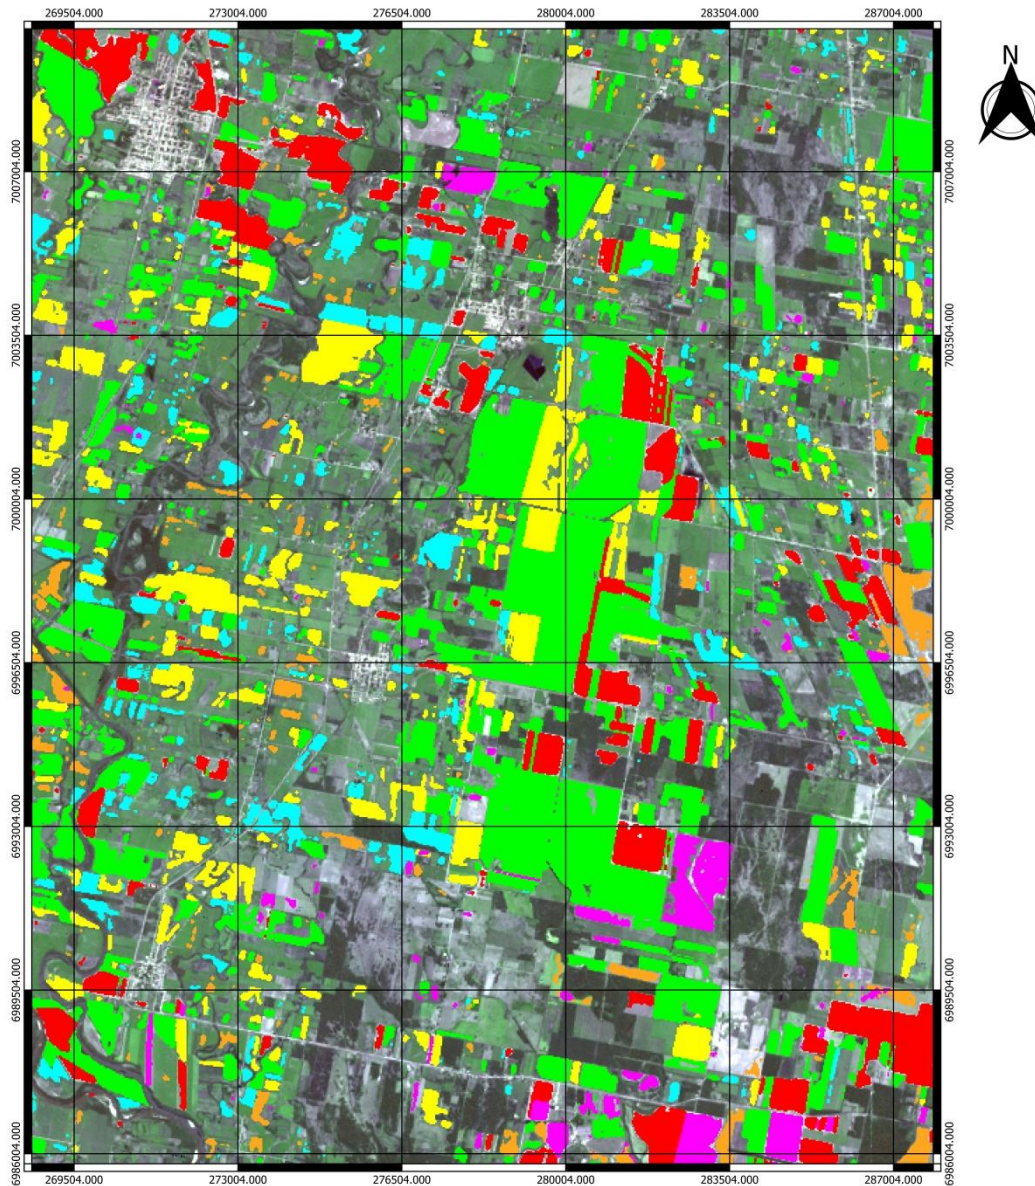
Anexo 5: Tabla de errores de Confusión y Omisión en las clasificaciones SAR

Clasificador	Errores	
	Comisión	Omisión
ISODATA	24.53%	15.93%
K-medias	16.05%	27.51%
SAM	11.19%	42.28%

Anexo 6: Mapa de Cosecha de caña de azúcar 2016



Mapa de la Cosecha de Caña de Azúcar, Tucuman. 2016



Leyenda

Cosecha de Caña de Azúcar 2016

- Cosechado entre 01/05 y 18/06
- Cosechado entre 18/06 y 20/07
- Cosechado entre 20/07 y 20/08
- Cosechado entre 20/08 y 06/09
- Cosechado entre 06/09 y 22/09
- Cosechado entre 22/09 y 9/11

Anexo 7: Vector de datos de campo y puntos aleatorios generados y Matriz de confusión obtenida a partir de los ROI de puntos aleatorios





Overall Accuracy = (174/183) 95.0820%		
Kappa Coefficient = 0.0000		
	Ground Truth (Pixels)	
Class	ROI:EVF: Layer	Total
Unclassified	9	9
Caña de Azúcar	174	174
Total	183	183

Anexo 8: Mapa de Corte en Pastizales Naturales Naturales, DOMEF 1500, en la Provincia de Bolzano, Italia



Mapa de Corte en Pastizales Naturales, Bolzano 2015



Leyenda


Fechas de Corte en Pastizales Naturales

- Corte de Pastizales Naturales entre el 14-6-2015 y el 26-6-2015
- Corte de Pastizales Naturales entre el 26-6-2015 y el 8-7-2015
- Corte de Pastizales Naturales entre el 8-7-2015 y el 20-7-2015

Anexo 9: Mapa de Inicio de crecimiento en Pastizales Naturales, DOMEF 1500, en la Provincia de Bolzano, Italia



Inicio de la Estación de Crecimiento, Bolzano 2015



0 1 2 3 4 km



Leyenda

Inicio de la Estación de Crecimiento en Pastizales Naturales

- Inicio de la Estación entre el 15-04-2015 y el 27-04-2015
- Inicio de la Estación entre el 27-04-2015 y el 09-05-2015
- Inicio de la Estación entre el 09-05-2015 y el 21-05-2015
- Inicio de la Estación entre el 21-05-2015 y el 02-06-2015
- Inicio de la Estación entre el 02-06-2015 y el 14-06-2015
- Inicio de la Estación despues del 14-06-2015

Referencias

- A.N.M.A.T. (1971). Código Alimentario Argentino. Retrieved September 8, 2017, from http://www.anmat.gov.ar/alimentos/normativas_alimentos_caa.asp
- Abdel-Rahman, E. M., Ahmed, F. B., & Van den Berg, M. (2010). Estimation of sugarcane leaf nitrogen concentration using in situ spectroscopy. *International Journal of Applied Earth Observation and Geoinformation*, 12(SUPPL. 1), 52–57. <https://doi.org/10.1016/j.jag.2009.11.003>
- Anino, P., & Pizzo, F. (2016). *Informes de cadenas de valor. Azúcar. Ministerio de Hacienda y Finanzas Públicas*. Retrieved from http://www.economia.gob.ar/peconomica/docs/SSPE_Cadena_Valor_Porcina.pdf
- Ariza Alexander. (2013). Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission). *Centro de Investigación Y Desarrollo En Información Geográfica Del IGAC -CIAF*, 46. <https://doi.org/10.5751/ES-06710-190329>
- Baghdadi, N., Boyer, N., Todoroff, P., El Hajj, M., & Bégué, A. (2009). Potential of SAR sensors TerraSAR-X, ASAR/ENVISAT and PALSAR/ALOS for monitoring sugarcane crops on Reunion Island. *Remote Sensing of Environment*, 113(8), 1724–1738. <https://doi.org/10.1016/j.rse.2009.04.005>
- Bertoldi, G., Brenner, J., Notarnicola, C., Greifeneder, F., Nicolini, I., Della Chiesa, S., ... Tappeiner, U. (2015). Monitoring soil moisture patterns in alpine meadows using ground sensor networks and remote sensing techniques. In *EGU General Assembly 2015, held 12-17 April, 2015 in Vienna, Austria. id.10374* (pp. 2831–2857). <https://doi.org/10.5194/gmd-7-2831-2014>
- Bouman, B. A. M. (1991). Crop parameter estimation from ground-based x-band (3-cm wave) radar backscattering data. *Remote Sensing of*

Environment, 37(3), 193–205. [https://doi.org/10.1016/0034-4257\(91\)90081-G](https://doi.org/10.1016/0034-4257(91)90081-G)

- Buemi, M. E. (2012). *Tratamiento de imágenes de radar de apertura sintética mediante filtros stack*. Universidad de Buenos Aires.
- Bustos, O. H., Frery, A. C., Lamfri, M. A., & Scavuzzo, C. M. (2004). *Técnicas Estadísticas en Teledetección Espacial*.
- Cabrera, A. L. (1971). Fitogeografía de la república Argentina. *Boletín de La Sociedad Argentina de Botánica*, 14, 1–42.
- CCRS. (2005). Material Educativo para Teledetección mediante Radares. *GlobeSAR Program Canada Centre for Remote Sensing*, 966. Retrieved from http://www.gep.uchile.cl/Biblioteca/Radar/gsarcd_s.pdf%5Cnftp://ftp.ccrs.nr.can.gc.ca/ad/MAS/globesar/spa/adv_pol_s.pdf
- Chambers, J. M., Cleveland, W. S., Kleiner, B., & Tukey, A. (1983). *Graphical Methods for Data Analysis*. (C. & Hall/CRC, Ed.), Wadsworth International Group. United States: Taylor & Francis Ltd.
- Chuvienco Salinero, E. (2006). *Teledetección ambiental: la observación de la Tierra desde el espacio*. Ariel,.
- Correa, J. C., & Gonzalez, N. (2002). *Graficos Estadísticos con R. Posgrado en Estadística, Universidad Nacional- Sede Medellín*. <https://doi.org/10.4067/S0071-17132000003500023>
- Craig Dobson, M., Pierce, L. E., & Ulaby, F. T. (1996). Knowledge-Based Land-Cover Classification Using ERS-I/JERS-1 SAR Composites. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, 34(1).
- De Leon, M. (2003). El manejo de los pastizales naturales. Retrieved September 11, 2017, from www.produccion-animjal.com.ar
- Department of the Interior U.S. Geological Survey. (2016). *Landsat 8 (L8) Data Users Handbook. DATA USERS HANDBOOK (Vol. 8)*.

- Department of the Interior, & U.S. Geological Survey. (2016). PROVISIONAL LANDSAT 8 SURFACE REFLECTANCE CODE (LASRC). *Product Guide, Version 7*.(October), 1–27.
<https://doi.org/10.1080/1073161X.1994.10467258>
- Earth Explorer (USGS). (n.d.). Earth Explorer. Retrieved September 25, 2017, from <https://earthexplorer.usgs.gov/>
- Edrosa, R. (2011). *Aplicacion de la Teledeteccion para el Monitoreo de Eventos Hidricos Superficiales mediante Imagenes Cosmo SkyMed*. Universidad Nacional de Córdoba.
- European Space Agency. (2012). The ASAR User Guide. Retrieved September 28, 2017, from <https://earth.esa.int/handbooks/asar/CNTR1-1-2.html>
- European Space Agency. (2013). *Sentinel-1 User Handbook*. Retrieved from https://sentinel.esa.int/documents/247904/685163/Sentinel-1_User_Handbook
- European Space Agency, UNESCO, & SARMAP. (2009). *Synthetic Aperture Radar Land Applications Tutorial, Part I: Background and Theory*. SARMAP ESA UNESCO.
- European Spacial Agency. (2014). Overview / Copernicus / Observing the Earth. Retrieved September 22, 2017, from http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4
- FAO. (2014). FAOSTAT. Retrieved February 14, 2017, from <http://www.fao.org/faostat/es/#data/QC>
- FAO. (2017). Sugarcane | Land & Water | Food and Agriculture Organization of the United Nations | Land & Water | Food and Agriculture Organization of the United Nations. Retrieved September 11, 2017, from <http://www.fao.org/land-water/databases-and-software/crop-information/sugarcane/en/>
- Ferral, A. (2013). *Análisis espacio-temporal del efecto del sistema de aireación*

artificial en el Embalse San Roque. Integración de datos de campo y técnicas geoespaciales. Universidad Nacional de Córdoba.

Ferrazzoli, P., Guerriero, L., & Schiavon, G. (1999). Experimental and model investigation on radar classification capability. *IEEE Transactions on Geoscience and Remote Sensing*. <https://doi.org/10.1109/36.752214>

Gimenez, Y. (2010). *Clasificación no supervisada : El método de k – medias.* Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales. Departamento de Matemática. Retrieved from http://cms.dm.uba.ar/academico/carreras/licenciatura/tesis/2010/Gimenez_Yanina.pdf

Guerschman, J. P. (2005). *Análisis regional del impacto de los cambios del uso de la tierra sobre el funcionamiento de los ecosistemas de la región pampeana (Argentina).* Facultad de Agronomía- Universidad de Buenos Aires. Retrieved from <http://orton.catie.ac.cr/cgi-bin/wxis.exe/?IsisScript=BIBUNFA.xis&method=post&formato=2&cantidad=1&expresion=mfn=009892>

Guerschman, J. P., Paruelo, J. M., Di Bella, C. M., Giallorenzi, M. C., & Pacin, F. (2003). Land cover classification in the Argentine Pampas using multi-temporal Landsat TM data. *International Journal of Remote Sensing*, 24(17), 3381–3402. <https://doi.org/10.1080/0143116021000021288>

Harris Geospatial Solution. (2013). ENVI Classic Help - Welcome to ENVI Classic Help. Retrieved April 13, 2017, from file:///C:/Program Files/Exelis/ENVI53/classic/help/ENVI3WHelp.htm

INDEC. (2017). Canasta Básica Alimentaria y Total. Retrieved September 8, 2017, from http://www.indec.gob.ar/nivel4_default.asp?id_tema_1=4&id_tema_2=27&id_tema_3=65

INTA. (2009). *Sistema de Clasificación de la Cobertura del Suelo. LCCS-FAO/UNEP. PNECO1643: Monitoreo de la cobertura y el uso del suelo a partir de sensores remotos (Vol. 1643).*

- Italian Space Agency. (2009). *COSMO-SkyMed SAR Products Handbook*. Retrieved from [http://www.e-geos.it/products/pdf/csk-product handbook.pdf](http://www.e-geos.it/products/pdf/csk-product%20handbook.pdf)
- Kandus, P. (2016a). Introducción a la Teledetección. Indices. Maestría en Aplicaciones Espaciales de Respuesta y Alerta Temprana a Emergencias de la FAMAF/UNC. Córdoba.
- Kandus, P. (2016b). Introducción a la Teledetección. Maestría en Aplicaciones Espaciales de Respuesta y Alerta Temprana a Emergencias de la FAMAF/UNC. Clasificación.
- Kandus, P. (2016c). Introducción a la Teledetección. Maestría en Aplicaciones Espaciales de Respuesta y Alerta Temprana a Emergencias de la FAMAF/UNC. Firmas Espectrales. Córdoba.
- Koppe, W., Gny, M. L., Hütt, C., Yao, Y., Miao, Y., Chen, X., & Bareth, G. (2013). Rice monitoring with multi-temporal and dual-polarimetric terrasars-X data. *International Journal of Applied Earth Observation and Geoinformation*, 21(1), 568–576. <https://doi.org/10.1016/j.jag.2012.07.016>
- Kruse, F. A., Lefkoff, A. B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J., & Goetz, A. F. H. (1993). The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(October 1992), 145–163.
- Kuntz, S., Poncet, F. v., Knuth, R., KelIndorfer, J., Köhl, M., Baldauf, T., ... Solberg, S. (2012). Status of X-Band SAR Applications in Forestry. *GEO-FCT, 3rd Science & Data Summit*, (August 2012), 15. Retrieved from http://www.researchgate.net/publication/251879651_White_Paper_Status_of_X-Band_SAR_Applications_in_Forestry
- Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2008). *Remote sensing and image interpretation*. John Wiley & Sons.
- Lin, H., Chen, J., Pei, Z., Zhang, S., & Hu, X. (2009). Monitoring sugarcane growth using ENVISAT ASAR data. *IEEE Transactions on Geoscience and Remote Sensing*. <https://doi.org/10.1109/TGRS.2009.2015769>

- Lopez Perez, A., Martinez Menes, M., & Fernandes Reynoso, D. (2015). Priorización de áreas de intervención mediante análisis morfométrico e índice de vegetación. *Tecnología Y Ciencias Del Agua*, 6(1), 121-137., 6(1), 121–137.
- Lopez Sanchez, J. M., & Ballester Berman, J. D. (2009). Potentials of polarimetric SAR interferometry for agriculture monitoring. *Radio Science*, 44(2), 1–20. <https://doi.org/10.1029/2008RS004078>
- Memarsadegh, N., & Rincon, R. (2013). NASA Computational Case Study: SAR Data Processing--Ground-Range Projection. *Computing in Science & Engineering*, 15, 92–95.
- Merg, C., Petri, D., Bodoira, F., & Nini, M. (2011). Mapas digitales regionales de lluvias, índice estandarizado de precipitación e índice verde. *Revista Pilquen, Sección Agronomía*, 13(11), 1-11., 11(ISSN-e 1851-2852), 12.
- Monserud, R. A. (1990). *Methods for Comparing Global Vegetation Maps*. International Institute for Applied Systems Analysis (Vol. 90–40).
- Moran, M. S., Inoue, Y., & Barnes, E. M. (1997). Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sensing of Environment*, 61(3), 319–346. [https://doi.org/10.1016/S0034-4257\(97\)00045-X](https://doi.org/10.1016/S0034-4257(97)00045-X)
- Murillo Sandoval, P. J., & Carbonell González, J. A. (2012). *Principios y aplicaciones de la percepción remota en el cultivo de la caña de azúcar en Colombia*. (Cenicaña, Ed.). Cali, Colombia.
- Notarnicola, C. (2016a). Introduction to SAR: basic concepts. Curso SAR, Maestría en Aplicaciones de Información Espacial, Instituto Gulich, CONAE.
- Notarnicola, C. (2016b). SAR Pre-processing. Curso SAR, Maestría en Aplicaciones de Información Espacial, Instituto Gulich, CONAE.
- Notarnicola, C., Asam, S., Jacob, A., Marin, C., Rossi, M., Stendardi, L., & Pascual, I. (2017). Mountain crop monitoring with multitemporal Sentinel-1

and Sentinel-2 imagery. In *MultiTemp 2017, Bruges, Belgium*. Retrieved from https://multitemp2017.vito.be/sites/multitemp2017.vito.be/files/1030-3-notarnicola_multitemp17.pdf

Paradis, L., Baghdadi, N., Cresson, R., Todoroff, P., Moinet, S., Paradis, L., ... Moinet, S. (2010). Multitemporal Observations of Sugarcane by TerraSAR-X Images. *Sensors*, *10*(10), 8899–8919.
<https://doi.org/10.3390/s101008899>

Parodi, L. R. (1977). *Enciclopedia argentina de agricultura y jardinería*. (ACME, Ed.) (3° Edición). Buenos Aires.

Paruelo, J. M., Guerschman, J. P., Baldi, G., & Di Bella, C. (2004). La estimación de la superficie agrícola: antecedentes y una propuesta metodológica. *Interciencia*, *29*, 421–427.

Pasolli, L., Notarnicola, C., Bertoldi, G., Della Chiesa, S., Niedrist, G., Bruzzone, L., ... Zebisch, M. (2014). Soil moisture monitoring in mountain areas by using high-resolution SAR images: Results from a feasibility study. *European Journal of Soil Science*, *65*(6), 852–864.
<https://doi.org/10.1111/ejss.12189>

Peratoner, G. (2015). webGRAS Guida all'utilizzo. Centro di Sperimentazione Agraria e Forestale Laimburg. Retrieved from www.webGRAS.laimburg.it

Peratoner, G. (2017). Agricoltura montana | Laimburg. Retrieved September 12, 2017, from <http://www.laimburg.it/it/ricerca/agricoltura-montana.asp>

Peréz Gutiérrez, C., & Muñoz Nieto, Á. L. (2006). *Teledetección: nociones y aplicaciones*. Universidad de Salamanca (Vol. 53).
<https://doi.org/10.1017/CBO9781107415324.004>

PlanEAR. (2017). PlanEAR - Mapas- Regiones Fitogeográficas según Cabrera. Retrieved September 11, 2017, from <http://www.lista-planear.org/index.php?accion=mapas>

Ploper, L. D., Fadda, G. S., & Olea, I. L. (2009). *en el mañana HOY* (1° Edición). Las Talitas : Estación Experimental Agroindustrial Obispo

Colombres, 2009. 348.

Portnoi, M. D. (2017). *Methods for sugarcane harvest detection using polarimetric*. Stellenbosch University.

Riedel, T., & Eckardt, R. (2013). Module 3202 : Biosphere - Agricultural Applications with SAR Data Content of Module Biosphere Forest biomass estimation using SAR data (Module 3210). Retrieved from <https://saredu.dlr.de/unit/agriculture>

Rios, L., Perez, G., & Felipe, A. (2017). *El mercado azucarero Argentino y análisis Económico de la zafra azucarera en Tucumán*.

Roca, J. V. (2014). La constelacion COSMO-SkyMed, radar de alta resolucion. In *Jornada "sistemas satelitales de alta resolucion"* (p. 101). Barcelona, España.

Romero, E. R., Digonzelli, P. A., & Scandaliaris, J. (2009). *Manual del cañero. Estación Experimental Las Talitas : Estación Experimental Agroindustrial Obispo Colombres, 2009*. Retrieved from <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=cidca.xis&method=post&formato=2&cantidad=1&expresion=mfn=009319>

Rouse, W., Haas, R. H., & Deering, D. W. (1974). MONITORING VEGETATION SYSTEMS IN THE GREAT PLAINS WITH ERTS. In *3rd Earth Resource Technology Satellite (ERTS) Symposium, vol. 1, p. 309-313*.

Ruiz Fernández, L. Á. (2013). Sensores de Microondas en teledeteccion: aspectos geometricos. Universidad Politecnica de Valencia, centro ETSI.

Salvia, M. (2016a). Teledetección en microondas : fundamentos físicos y extracción de información. Parámetros y procesos que influyen en las características de la imagen SAR. Mecanismos de interacción. Curso SAR. Maestria de aplicaciones en informacion espacial. UNC.

Salvia, M. (2016b). Teledetección en microondas : fundamentos físicos y extracción de información. Speckle. Curso SAR. Maestria de aplicaciones

en informacion espacial. UNC.

Salvia, M. (2016c). Teledetección en microondas: fundamentos físicos y extracción de información. Ecuacion del Radar, Magnitudes, Calibracion. Curso SAR. Maestria de aplicaciones en informacion espacial. UNC.

Sinha, S., Jeganathan, C., Sharma, L. K., & Nathawat, M. S. (2015). A review of radar remote sensing for biomass estimation. *International Journal of Environmental Science and Technology*, 12(5), 1779–1792.
<https://doi.org/10.1007/s13762-015-0750-0>

Sistema de Información y Gestión Agrometeorológico INTA. (2017). Datos Históricos EEA Famailla, Estación Nimbus THP, Latitud: -27.019 Longitud: -65.381, Altura: 379.79 msnm, Ubicacion: Ruta Prov. 301, Km 32 CP: 4132. Retrieved October 23, 2017, from <http://siga2.inta.gov.ar/en/datoshistoricos/>

Soria, F. J., & Fandos, C. (1999). *Relevamiento Satelital de la Provincia de Tucumán. Determinación del área cultivada con citrus y granos, y produccion de caña de azucar*. Tucumán, Argentina.

Soria, F. J., Fandos, C., Scandaliaris, P., & Carreras Baldrés, J. (2015). *Relevamiento satelital de los principales cultivos de la provincia De Tucuman*. Tucumán, Argentina.

Steven, M. D., & Clarck, J. A. (1990). *Applications of Remote Sensing in Agriculture*. Butterworth-Heinemann.

USDA. (1999). *Soil Taxonomy*. <https://doi.org/10.1017/S0016756800045489>

Vazquez Espinoza de los Monteros, R. A. (2015). *Clasificación de cultivos agrícolas temporales en imágenes de alta resolución usando técnicas de cómputo inteligente*.

Vermote, E., Justice, C., Claverie, M., & Franch, B. (2016). Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment*, 185, 46–56.
<https://doi.org/10.1016/j.rse.2016.04.008>

- Vicini, L. E., & Vicini, C. L. (2010). *Mecanización del Cultivo de Caña de Azúcar una mirada desde 1949 al 2050. Informes Técnicos del Proyecto PERCOP II* (Vol. 2).
- Violini, S. (2016). *Uso de suelo agrícola en la zona central de Córdoba : análisis de datos espaciales multisensor para su estudio y gestión*. Universidad Nacional de Córdoba.
- Weeks, J. R. (2010). *Remote Sensing and Digital Image Processing* (Vol. 10). Springer. https://doi.org/10.1007/978-1-4020-4385-7_3
- Zhao, D., Reddy, K. R., Gopal, V., & Reddy, V. R. (2005). Nitrogen deficiency effects on plant growth , leaf photosynthesis , and hyperspectral reflectance properties of sorghum. *European Journal of Agronomy*, 22, 391–403. <https://doi.org/10.1016/j.eja.2004.06.005>
- Zuccardi, R., & Fadda, G. S. (1985). *Bosquejo Agrológico de la provincia de Tucumán. Facultad de Agronomía y Zootécnia*.