



## **Maestría en aplicaciones de información espacial**

---

### **TESIS DE MAESTRÍA**

### **“Detección y mapeo de sequía utilizando imágenes ópticas y SAR”**

---

**Maestrando:**  
**Ing. Agr. Santiago Bustos Revol**

**Director:**  
**Mgtr. Ignacio Gastón Pascual**  
Subgerencia de Aplicaciones y Productos,  
Gerencia de Observación de la Tierra, CONAE

Falda del Cañete, 30 de agosto de 2021



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

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

---

## Agradecimientos

---

Al Estado nacional, a CONAE y VENG SA por darme la oportunidad de seguir creciendo como profesional.

Al instituto Mario Gulich que hizo posible esta maestría gracias a su gran grupo humano y profesional.

A la Agencia Espacial Italiana, al Eurac y a Claudia Notarnicola por la beca de investigación en Bolzano, Italia.

A mi esposa Nadia, por su amor incondicional y su apoyo. A mi familia, en especial a mi hermano Federico, quien desde el cielo me empuja a avanzar siempre.

A mi director, colega y amigo, Ignacio Pascual, quien puso toda su paciencia y dedicación para enseñarme, guiarme y acompañarme en este proceso.

A Laura Frulla y Álvaro Soldano quienes confiaron en mi para continuar este camino de aprendizaje.

A cada uno de mis compañeros y amigos de la MAIE con quienes compartí dos años maravillosos de cursado, estudiando y compartiendo grandes momentos. En especial a Yenni quien además, dedicó muchas horas enseñándonos matemáticas. A Joni y Paula con quienes tuve el placer de compartir una gran experiencia de vida y profesional en Italia.

A mis compañeros de trabajo con quienes pasamos muchas horas de campaña tomando datos para esta tesis.



---

## Resumen

---

En este trabajo se utilizó el algoritmo SVR a escala local para medir la performance en la estimación de la humedad de suelo a partir de imágenes SAR principalmente, aunque también se utilizaron otras fuentes de información complementaria como: temperatura y precipitaciones (extraídas de una estación meteorológica local), datos de NDVI (extraídos del sensores ópticos como Sentinel-2), índices de sequía como PDSI y de vegetación como VCI (este último fue extraído a partir de imágenes MODIS). El objetivo fue comprobar si existió algún tipo de déficit hídrico detectado con imágenes SAR, que pudiera haber afectado a los cultivos agrícolas en la zona de Bell Ville- Monte Buey en el la campaña agrícola 2017/18.

Los resultados del coeficiente de determinación no superaron valores de 0.5 a pesar de haber utilizado variables complementarias que aportaron información para explicar la humedad del suelo y la influencia de la vegetación en ésta. Se concluyó que no es adecuado la utilización del algoritmo SVR para recuperar la humedad de suelo a partir de sensores banda C con las polarizaciones VH y VV sobre lotes agrícolas en el área estudiada.

Por otro lado se realizaron mapas de déficit hídrico donde se identificaron cuales son las posibles áreas bajo régimen de sequía, cual fue su intensidad, su duración y como fue la dinámica de la sequía en el tiempo. Además fue factible calcular la superficie bajo estrés en cada fecha de manera general y discriminando por intensidad del estrés (déficit hídrico leve, moderado o severo). La confiabilidad de los resultados podría incrementarse a medida que aumente la duración de la serie.

**Palabras clave:** Radar de Apertura Sintética (SAR), Banda C, Support Vector Regression (SVR), humedad de suelo, sequía.

---

## Abstract

---

In this work the SVR algorithm was used at a local scale to measure the performance in the estimation of soil moisture from SAR images mainly, although other sources of complementary information were also used such as: temperature and precipitation (extracted from a local weather station), NDVI data (extracted from optical sensors such as Sentinel-2), drought indices such as PDSI and vegetation indices such as VCI (the latter was extracted from MODIS images). The objective was to check if there was any type of water deficit detected with SAR images, which could have affected agricultural crops in the area of Bell Ville- Monte Buey in the 2017/18 agricultural year.

The results of the determination coefficient values did not exceed 0.5 despite using complementary variables that provided information to explain soil moisture and the vegetation influence on the soil. It was concluded that it is not appropriate to use the SVR algorithm to recover soil moisture from C-band sensors with VH and VV polarizations on agricultural fields in the studied area.

On the other hand, water deficit maps were made where the possible areas under drought regime were identified, what was its intensity, its duration and how was the dynamics of drought in time. It was also feasible to calculate the area under stress in a general way and discriminating by stress intensity (mild, moderate or severe water deficit). The reliability of the results could be increased with increasing duration of the series.

**Keywords:** Sintetic Aperture Radar (SAR), SVR, C band, soil moisture, drought.

---

# Índice de Contenidos

---

<b>1. Introducción</b>	<b>1</b>
1.1. Preguntas a responder . . . . .	6
1.2. Objetivos . . . . .	6
1.2.1. General . . . . .	6
1.2.2. Específicos . . . . .	6
1.3. Estructura de la tesis . . . . .	7
<b>2. Marco Teórico</b>	<b>8</b>
2.1. Teledetección . . . . .	8
2.2. Radar . . . . .	10
2.2.1. Distorsiones geométricas . . . . .	14
2.2.2. Distorsiones radiométricas . . . . .	15
2.2.3. Interacción de la señal con la superficie . . . . .	16
2.3. Relación Agua- Suelo- Planta . . . . .	18
2.4. Cultivos . . . . .	22
<b>3. Área de estudio</b>	<b>24</b>
3.1. Información general . . . . .	24
3.2. Clima . . . . .	26
3.2.1. Régimen térmico . . . . .	26

3.2.2. Régimen hídrico . . . . .	26
3.3. Suelos . . . . .	27
3.4. Vegetación . . . . .	30
<b>4. Materiales y Métodos</b>	<b>34</b>
4.1. Materiales . . . . .	34
4.1.1. Imágenes SAR: Sentinel-1 . . . . .	34
4.1.2. Imágenes ópticas: Sentinel-2 . . . . .	37
4.1.3. Datos de Humedad de suelo . . . . .	38
4.1.4. Datos Climatológicos: Estación meteorológica del IPEA 293 en Bell Ville; y Serie histórica WorldClim . . . . .	40
4.1.5. Índices de sequía: PDSI y VCI . . . . .	43
4.1.5.1. Índice de Palmer PDSI . . . . .	43
4.1.5.2. Índice de la condición de la vegetación VCI . . . . .	45
4.2. Métodos . . . . .	48
4.2.1. Preprocesamiento de imágenes Sentinel-1 . . . . .	48
4.2.2. Procesamiento de datos . . . . .	49
4.2.3. El Modelo: Support Vector Regression (SVR) . . . . .	51
4.2.4. Mapa de déficit hídrico . . . . .	53
<b>5. Resultados</b>	<b>55</b>
5.1. Análisis de Sensibilidad . . . . .	55
5.2. El Modelo: Support Vector Regression (SVR) . . . . .	61
5.3. Mapa de déficit hídrico . . . . .	64
5.3.1. Superficie del déficit hídrico . . . . .	67
<b>6. Conclusiones y propuestas de investigación</b>	<b>70</b>
6.1. Propuestas de investigación . . . . .	72
<b>Anexos</b>	<b>78</b>
<b>A. Código en Python del algoritmo SVR</b>	<b>78</b>

<b>B. Código en GEE de NDVI</b>	<b>80</b>
<b>C. Código en GEE de PDSI</b>	<b>82</b>
<b>D. Código en R de VCI</b>	<b>83</b>
<b>E. Tabla de comprobación de remuestreo de píxel</b>	<b>90</b>

---

## Índice de figuras

---

1.1. Tipos de sequías . . . . .	3
2.1. Espectro Electromagnético . . . . .	9
2.2. Microondas en el EEM . . . . .	11
2.3. Longitud de onda y penetración en el suelo y vegetación de la banda X,C y L	12
2.4. Polarización de la onda electromagnética . . . . .	13
2.5. Ángulo de incidencia de la onda electromagnética . . . . .	14
2.6. Distorsiones geométricas . . . . .	15
2.7. Speckle: Origen y tipo de interferencia . . . . .	16
2.8. Reflectores tipo esquina o Corner Reflectors . . . . .	17
2.9. Mecanismos de Retrodispersión . . . . .	17
2.10. Fases del suelo . . . . .	18
2.11. Agua disponible para las plantas según la textura del suelo . . . . .	21
2.12. Situación de Rendimiento de un cultivo . . . . .	23
2.13. Consumo de agua promedio acumulado durante el ciclo de cultivos de Maíz, Trigo, Soja 1ª y Soja 2ª en el sur de la Provincia de Santa Fe . . . . .	23
3.1. Área de estudio en Argentina: Bell Ville- Monte Buey, Córdoba . . . . .	25
3.2. Precipitación y Temperatura media mensual, Bell Ville, Córdoba . . . . .	26
3.3. Balance Hídrico Climático, Bell Ville, Córdoba . . . . .	26

3.4. Zonas Agro-económicas Homogéneas (ZAHs) de la Provincia de Córdoba .	27
3.5. Taxonomía hasta el nivel de Subgrupo del Departamento Unión . . . . .	29
3.6. Capacidad de uso de los suelos y drenaje del departamento Unión . . . . .	30
3.7. Regiones Fitogeográficas de la República Argentina . . . . .	31
3.8. Superficie principales cultivos del departamento Unión . . . . .	32
3.9. Evolución del área (ha-1) y producción (tn) de los principales cultivos del departamento Unión . . . . .	32
3.10. Superficie cultivos vs. ganadería en el departamento Unión . . . . .	33
4.1. Sentinel-1: Modos de Adquisición . . . . .	35
4.2. Sentinel-1: Revisita, frecuencia de Cobertura . . . . .	36
4.3. Descarga imágenes Sentinel-1A sobre Bell Ville, Córdoba . . . . .	37
4.4. Core Site de la red telemétrica SAOCOM, Bell Ville- Monte Buey, Córdoba	38
4.5. Sitio de medición automático de la Red Telemétrica SAOCOM . . . . .	39
4.6. Temperaturas medias diarias, Bell Ville, Córdoba . . . . .	41
4.7. Precipitaciones medias mensuales, Bell Ville, Córdoba . . . . .	41
4.8. Precipitaciones medias mensuales vs. precipitaciones medias mensuales his- tóricas, Bell Ville, Córdoba . . . . .	42
4.9. Diferencia entre precipitaciones medias mensuales y precipitaciones medias mensuales históricas, Bell Ville, Córdoba . . . . .	42
4.10. Índice de severidad de sequía de Palmer . . . . .	44
4.11. Índice de condición de la vegetación de Kogan de enero, febrero y marzo del 2018 cada 16 días . . . . .	46
4.12. Índice de condición de la vegetación de Kogan de enero, febrero y marzo del 2018 cada 16 días . . . . .	47
4.13. Salida de ENVI. Z profile sobre el sitio de muestreo n°8 en Monte Buey, Córdoba . . . . .	50
4.14. Modelo SVR . . . . .	52
4.15. Diagrama del funcionamiento del Algoritmo SVR. . . . .	53
4.16. Diagrama de flujo de la creación del mapa de sequía. . . . .	53
5.1. Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo en la campaña 2018-19 . . . . .	56

5.2. Evolución de la humedad de suelo medida en campo y retrodispersión en VH y VV de Sentinel-1 en el sitio 5 . . . . .	56
5.3. Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo medida en campo en el sitio 5 . . . . .	56
5.4. Evolución del NDVI del lote y retrodispersión en VH y VV de Sentinel-1 en el sitio 5 . . . . .	57
5.5. Correlación entre retrodispersión en VH y en VV vs. el NDVI del lote en el sitio 5 . . . . .	57
5.6. Correlación entre retrodispersión en VH y en VV vs. la humedad del suelo del lote en el sitio 5 donde los NDVI son menores a 0.2 . . . . .	58
5.7. Evolución de la humedad de suelo medida en campo y retrodispersión en VH y VV de Sentinel-1 en el sitio 7 . . . . .	58
5.8. Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo medida en campo en el sitio 7 . . . . .	58
5.9. Evolución del NDVI del lote y retrodispersión en VH y VV de Sentinel-1 en el sitio 7 . . . . .	59
5.10. Correlación entre retrodispersión en VH y en VV vs. NDVI en el sitio 7 . .	59
5.11. Evolución de la humedad de suelo medida en campo y retrodispersión en VH y VV de Sentinel-1 en el sitio 3 . . . . .	59
5.12. Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo medida en campo en el sitio 3 . . . . .	60
5.13. Evolución del NDVI del lote y retrodispersión en VH y VV de Sentinel-1 en el sitio 3 . . . . .	60
5.14. Correlación entre retrodispersión en VH y en VV vs. NDVI en el sitio 3 . .	60
5.15. Diagramas de caja de los datos de humedad de suelo medidos por los sensores Hydra Probe II en todos los sitios de muestreo del área de estudio . . . .	61
5.16. Mapa de déficit hídrico del 21 de marzo del 2018 (proyección WGS 84) . .	64
5.17. Histograma déficit hídrico del 21 de marzo de 2018 (ENVI versión 5.5.1) .	65
5.18. Histogramas de los mapas de déficit hídricos ordenados cronológicamente, Bell Ville, Córdoba . . . . .	68
5.19. Imágenes de los mapas de déficit hídricos ordenados cronológicamente, Bell Ville, Córdoba . . . . .	68
5.20. Histogramas e imágenes de los VCI ordenados cronológicamente . . . . .	69
5.21. Estadísticas extraídas de los histogramas de VCI . . . . .	69



E.1. Tabla comparativa de una imagen con píxel de 10x10 contra una de 100x100	91
---	----

---

## Índice de tablas

---

4.1. Tabla con datos SAR, NDVI, PDSI, VCI, temperatura, precipitaciones y humedad de suelo del lote 66 . . . . .	51
5.1. Tratamientos en SVR . . . . .	63
5.2. Superficie por condición hídrica a la fecha del 21 de marzo del 2018 . . . .	67

---

## Acrónimos

---

**CONAE** Comisión Nacional de Actividades Espaciales

**SAR** Radar de Apertura Sintética

**ESA** European Spacial Agency

**SAOCOM** Satélite de Observación con Microondas

**DEM** Modelo Digital de Elevación

**EMIS** Equipo de Medición In Situ

**SMN** Servicio Meteorológico Nacional

**IPEA** Instituto Provincial de Educación Agrotécnica

**INTA** Instituto Nacional de Tecnología Agropecuaria

**SNAP** Sentinel Application Platform

**GEE** Google Earth Engine

**NDVI** Normalized Diference Vegetation Index

**SVM** Support Vector Machine

**SVR** Support Vector Regression

**CREAN** Centro de Relevamiento y Evaluación de Recursos Agrícolas y Naturales

**MAGyP** Ministerio de Agricultura ganadería y Pesca

**SPI** Standar Precipitation Index

**PDSI** Palmer drought Severity Index

**VCI** Vegetation Condition Index

**EVI** Enhanced Vegetation Index

**MAIE** Maestría en aplicaciones de información espacial

**ONU** Organización de las Naciones Unidas

**SPEI** Standardized Precipitation Evapotranspiration Index

**Rp** Rendimiento potencial

**Ra** Rendimiento limitado por agua

**Rr** Rendimiento real

**EEM** Espectro Electro-magnético

**ZAHs** Zonas Agroeconómicas Homogéneas

**NASA** National Aeronautics and Space Administration

**GRD** Ground Range Detected

---

## Glosario

---

**Espectro Electromagnético (EEM):** El EEM es una representación de la energía en función de la frecuencia o bien según la longitud de la onda. La energía viaja a la velocidad de la luz en forma de ondas y se puede detectar a través de su interacción con el medio ambiente. El EEM se puede describir según: frecuencia, polarización y longitud de onda (inversamente proporcional a la frecuencia) [1].

**Radar de Apertura Sintética (SAR):** Es un sistema de radar de iluminación lateral que produce una imagen de resolución fina de la superficie terrestre. A medida que avanza, el radar ilumina hacia franjas continuas y paralelas entre sí, de la superficie en estudio y acumula la información de las microondas que se reflejan. La señal que se graba a bordo, se procesa apropiadamente para formar una imagen digital. Mediante un procesamiento digital de la señal, la imagen puede enfocarse y obtenerse así, una resolución mejor que la de un radar convencional [1].

**Sequía:** Es la deficiencia de precipitaciones en una área determinada, pudiendo ser de distinta magnitud. Resulta difícil determinar con precisión cuando comienza y cuando termina, ocasionando efectos socio-económicos muy adversos dependiendo de su duración.

**Teledetección:** Se puede definir a la teledetección o teleobservación como la técnica que permite adquirir imágenes de la superficie terrestre desde una plataforma satelital, ya sea a partir de la energía reflejada de la luz solar o bien por la reflexión de un haz artificial emitido por el propio sensor [2].

**Monsónico:** Se considera que el régimen es de tipo monzónico cuando las precipitaciones presentan mayor concentración parcial o total en el semestre cálido (de octubre a marzo). Se lo puede diferenciar cuando el porcentaje de precipitación media del semestre cálido es mayor o igual al 60 % de la precipitación media anual (100 %) [3].

**Isohigro:** El Noreste del país, especialmente la provincia de Misiones y este de las de Entre Ríos y Corrientes, presentan régimen de tipo isohigro, el que se puede extender a la región de la Mesopotamia y el noreste de la provincia de Buenos Aires. El término “isohigro” deriva de iso (igual) e higo (humedad). Este tipo climático se aplica a las regiones en las cuales las precipitaciones ocurren todo el año y se distribuyen uniformemente a lo largo del año [3].

**Mediterráneo:** El régimen es de tipo mediterráneo cuando las precipitaciones presentan mayor concentración parcial o total en el semestre frío (de abril a setiembre). Se lo puede diferenciar cuando el porcentaje de precipitación media del semestre frío es mayor o igual al 60 % de la precipitación media anual (100 %) [3].

**Densidad del suelo:** Mediante la determinación de la densidad se puede obtener la porosidad total del suelo. Se refiere al peso por volumen del suelo. Existen dos tipos de densidad, real y aparente. La densidad real, de las partículas densas del suelo, varía con la proporción de elementos constituyendo el suelo y en general está alrededor de 2,65. Una densidad aparente alta indica un suelo compacto o tenor elevado de partículas granulares como la arena. Una densidad aparente baja no indica necesariamente un ambiente favorecido para el crecimiento de las plantas [4].

# CAPÍTULO 1

---

## Introducción

---

La Teledetección o el sensado remoto es la técnica que permite adquirir imágenes de la tierra a partir de sensores instalados en plataformas espaciales o satélites. Los sensores satelitales para la observación de la tierra se pueden clasificar de muchas maneras:

- Según su forma de emitir o recibir la energía pueden llamarse activos o pasivos.
- Según el dominio del espectro electromagnético en que trabajan energéticamente se llaman ópticos, radares, lidar, térmicos, etc.
- Según el tipo de órbita pueden ser geo-estacionarios o helio-sincrónicos, si observan la misma porción de la tierra a 36.000 km de altura o tienen orbita polar a una altura menor a los 1.000 km de altura respectivamente.

En este sentido las imágenes provistas por un Radar de Apertura Sintética (SAR por sus siglas en inglés) son herramientas muy valiosas que, dependiendo de las condiciones de suelo, la pendiente y la vegetación, puede proporcionar indirectamente información correlacionada con la humedad de suelo. La ventaja del uso del radar en contraposición a los sensores ópticos es que pueden obtener imágenes de la superficie terrestre tanto de día como de noche y pueden atravesar las nubes ya que son prácticamente invisibles a las microondas [2] [5] [6].

Se entiende a la sequía como la deficiencia de precipitaciones en una área determinada, pudiendo ser de distinta magnitud dependiendo de su duración. Resulta difícil determinar con precisión cuando comienza y cuando termina, pudiendo ocasionar efectos socio-económicos muy adversos. Como fenómeno meteorológico, puede ocurrir sobre cualquier superficie, independientemente del subtipo climático dominante (mediterráneo, monzónico o isohigro), incluso en aquellas donde acontecen abundantes precipitaciones. Se distingue de la aridez en que la deficiencia de precipitaciones es una característica normal en este tipo de climas mientras que sequía es una anomalía de que puede ocurrir en cualquier ecosistema en cualquier parte del mundo [7] [8].

Las sequías se clasifican según su génesis y/o efectos adversos, en:

- Sequía meteorológica

Se produce cuando el descenso de las precipitaciones es prolongado en el tiempo e inferior a la media en un registro de 30 años o más. Su intensidad y extensión en el tiempo está relacionada con la aparición de otros tipos de sequía.

Existen muchas definiciones de sequía meteorológica, entre ellas Palmer (1965) la define como el «intervalo de tiempo, generalmente con una duración del orden de meses o años, durante el cual el aporte de humedad en un determinado lugar cae consistentemente por debajo de lo climatológicamente esperado o del aporte de humedad climatológicamente apropiado», mientras que Russell *et al.* (1970) son más concisos: «Falta prolongada de precipitación, inferior a la media» [9].

- Sequía agrícola

Ocurre cuando una disminución considerable de las precipitaciones y de la disponibilidad de agua en el suelo se combina con una aumento de la evapotranspiración dando como resultado una disminución de los rendimientos potenciales de los cultivos (limitado por agua). Esta disminución de los rendimientos puede ser de distinta magnitud dependiendo de la severidad de la sequía. En cuanto a la ganadería, las mismas repercuten en una menor producción de materia seca por hectárea de las pasturas influyendo directamente en la carga animal del campo y en definitiva influirá en la producción de crías por hectárea, o en una merma de los kilos de carne o leche producidos [9].

El rendimiento potencial de los cultivos es cuando se llega al nivel máximo de producción. Es decir cuando puede expresar su máximo potencial genético y se dan todas las condiciones ambientales (radiación y temperatura), sin limitaciones de agua ni nutrientes y sin haber sido dañado por plagas ni enfermedades [10].

- Sequía hidrológica

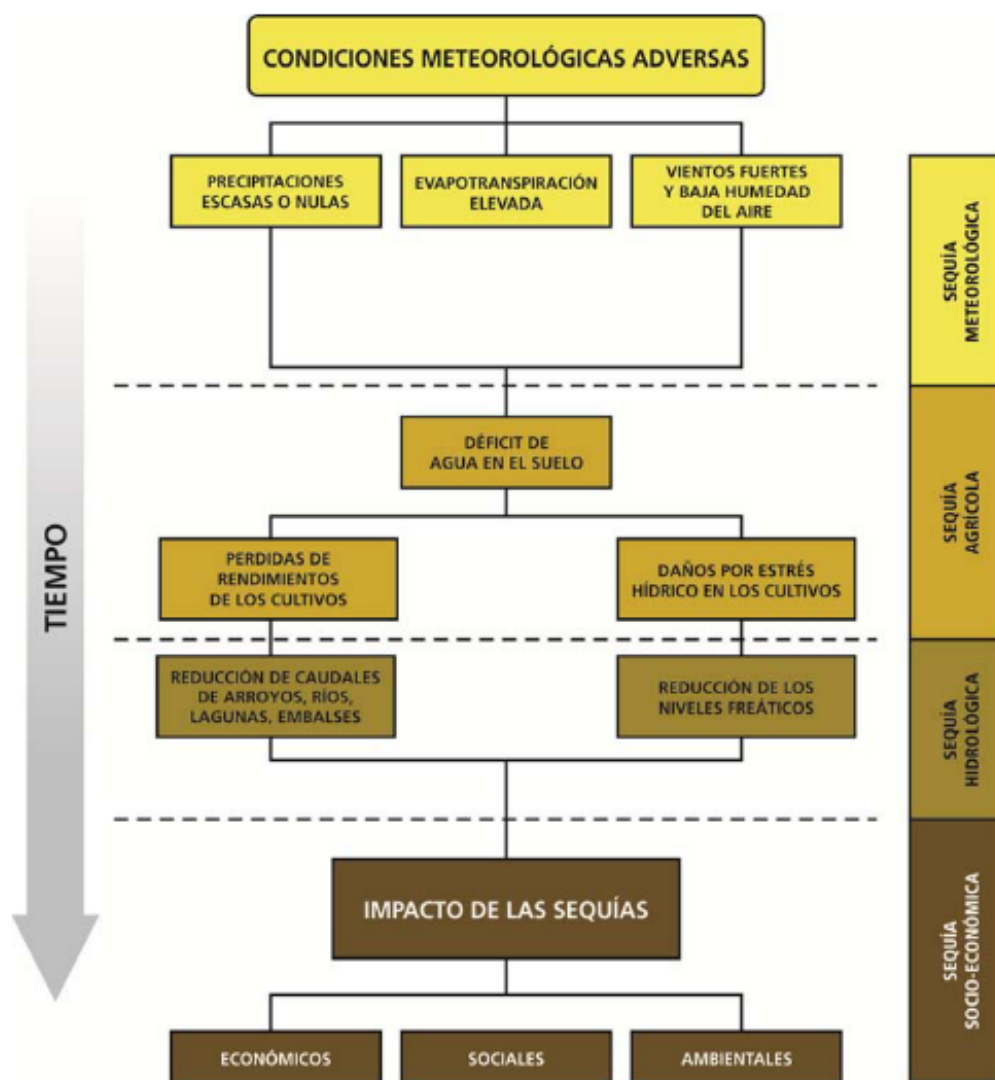
Se presenta cuando las condiciones meteorológicas adversas continúan temporalmente agudizando la intensidad de la sequía de manera tal que se presenta una disminución de las aguas superficiales en los ríos y los lagos, y también produce que las aguas subterráneas alcancen niveles inferiores a los normales [9].

- Sequía socio-económica

Ocurre como consecuencia de las sequías previamente descriptas generando problemas directos a las comunidades tanto por la falta de agua para su vida diaria o la producción de alimentos como para sus actividades económicas [9].

Los tipos enunciados se presentan en el orden de aparición del evento y con el consecuente impacto negativo. La Figura 1.1 describe los efectos negativos de la sequía y el nombre que le corresponde según la clasificación antes descripta. Se observa que a medida que pasa el tiempo, los efectos negativos de la misma se agravan ocasionando diversas pérdidas que afectan a distintos sectores de la sociedad.





**Figura 1.1:** Tipos de sequías [7]

Las sequías traen aparejado consecuencias sobre distintos aspectos, causando una disminución de los rendimientos de los cultivos agrícolas y la baja en la producción ganadera por la merma en la cantidad y calidad de las pasturas. A medida que pasa el tiempo la falta de precipitaciones agrava la condición de la región. El material vegetal que muere por falta de agua deja los campos susceptibles a incendios y expuestos a la erosión por la ausencia de cobertura vegetal del suelo. La severidad del evento puede llegar a ser extrema e irreversible desertificando la región. Si se consideran las pérdidas económicas, las sequías, pueden alcanzar magnitudes similares o superiores a otro tipo de eventos catastróficos tales como, huracanes, inundaciones, erupciones volcánicas o tsunamis. Pero las pérdidas no sólo son económicas o ambientales sino también sociales ya que trae aparejado una disminución en la producción de los alimentos o también insuficiencia en el suministro de agua para la vida normal de una población [8].

Argentina cuenta con instituciones de gran trayectoria en investigación en la temática como el Instituto Nacional de Tecnología Agropecuaria (INTA) y el Centro de Relevamiento y Evaluación de Recursos Agrícolas y Naturales (CREAN) que registran y estudian estas sequías. Desde INTA se realizan informes periódicos de la situación hídrica de cada región. Un ejemplo de esto puede mencionarse en el «Informe de sequía en el territorio del este de Córdoba de la campaña 2017-2018» en el que se evaluó el grado de afectación de la falta de

precipitaciones sobre la producción agrícola y ganadera del territorio del Este de Córdoba, dejando en evidencia que el mes de marzo del 2018 registró las precipitaciones más bajas y la evapotranspiración más alta de los últimos 10 años y también el mes de febrero de 2018 registró el nivel freático más bajo de los últimos 5 años. Del mismo modo el CREAN comenzó en el año 1980 a realizar seguimiento y validación de sequías mediante el índice de Palmer (PDSI), el índice estandarizado de precipitación (SPI) de McKee et al. y mediante el uso de sistemas de información geográfica permiten el continuo monitoreo de las condiciones de los recursos naturales a nivel nacional. En ese sentido se registraron sequías de distinta magnitud en distintas regiones de Argentina los años 1988/89, 1995, 1999, 2008/09, 2011/12 y 2017/18 [11].

A su vez, la problemática tiene una significancia a nivel mundial en el que muchos países e instituciones internacionales como la ONU están abocados a conocer, estudiar y monitorear las sequías para establecer estrategias para la detección, mitigación y respuesta temprana para este tipo de catástrofes. Como ejemplo de ello el CREAN realizó un estudio cuantificando las pérdidas económicas de sólo tres departamentos (Marcos Juárez y Unión de la provincia de Córdoba y General López en la provincia de Santa Fe) para la sequía de la campaña 2011/12 registrando pérdidas desde un 19 a un 30 % en el cultivo de soja que significaron una disminución de 350 millones de dólares en los ingresos por ventas de la oleaginosa [12]. Del mismo modo, el Monitor de sequía global (SPEI) ofrece información casi en tiempo real sobre las condiciones de sequía a escala global [13].

A partir de estos estudios o investigaciones científicas y dependiendo de la intensidad y duración de la sequía se declara Emergencia o Catástrofe en la región donde el Estado interviene colaborando con los damnificados con créditos para reparar daños y postergando obligaciones impositivas a los productores agropecuarios. La Ley nacional 26.509, reglamentada por Decreto 1712/2009 determina que un evento climático será catástrofe o emergencia de acuerdo con el porcentaje de pérdida generado en el campo productivo. Si la pérdida del siniestro es mayor al 50 % la misma se considera emergencia, en cambio si supera el 80 % se considera catástrofe agrícola [14].

Existen numerosas formas y medios para estimar la humedad de suelo y la sequía en un área determinada. Por un lado la humedad de suelo se puede obtener por diferencia de pesos de una muestra luego de secarla en estufa a 105°C por 24 hs. o bien por medio de sondas que miden la constante dieléctrica y a partir de ella se calcula la humedad de suelo por medio de una ecuación que depende del tipo de suelo. Por otro lado existen los índices de sequía que se utilizan para identificar, clasificar y monitorear las condiciones de sequía [15]. Permiten describir una sequía en cuanto a la intensidad, la duración y la extensión espacial de condiciones meteorológicas anómalas y, por lo tanto, apoyan los sistemas de toma de decisiones (por ejemplo, activando acciones de mitigación).

Los índices de sequía más populares son:

- Índice de Precipitación Estandarizado (SPI) que se basa únicamente en la precipitación, permite comparar zonas con diversidad de condiciones gracias a su principio estadístico; el cual se basa en el número de desviaciones que existe entre la precipitación actual y la histórica [16].

- Índice de Severidad de la Sequía de Palmer (PDSI) que se calcula en función de la demanda de agua (evapotranspiración) y las pérdidas (escorrentía) [17].

Ambos índices son estimadores de sequía a largo plazo pero no herramientas de predicción de sequía.

Algunos estudios han investigado el fenómeno de cambio climático donde indican los efectos sobre la biosfera en la actualidad [18]. Además aseguran que en el último siglo el planeta ha sufrido grandes cambios como la reducción de los hielos y superficie cubierta por nieve, se redujo el tiempo en que los lagos permanecen congelados durante el año, aumentó el nivel medio del mar, cambios en los patrones de precipitaciones, la frecuencia e intensidad de eventos climáticos extremos, etc [18]. En consecuencia resulta de utilidad indagar sobre esta problemática con todos los recursos que se tengan disponibles, entre estos la teledetección es una herramienta sumamente valiosa ya que permite hacer un análisis a bajo costo y en poco tiempo, con una alta frecuencia de adquisición de datos y captación en todos los rincones del planeta, dificultad que experimentan las redes de monitoreo en tierra [16]. Esto le permite a productores, científicos y autoridades gubernamentales puedan tomar decisiones para mitigar sus efectos negativos.

En un país como Argentina donde una parte importante de sus ingresos en la balanza comercial son debido a la exportación de materias primas (principalmente soja, maíz y trigo) y la mayor parte de esa producción agrícola es en condiciones de secano. Por lo tanto es de gran valor la información generada para prevenir y mitigar el efecto de las limitaciones del agua en los cultivos o pasturas, factor fundamental para fomentar el desarrollo de las producciones primarias y las economías regionales de nuestro país.

El siguiente trabajo busca identificar cual es la superficie que se encuentra bajo un régimen de sequía o bien cual es el área que comparativamente con respecto a años anteriores, recibió una menor cantidad de precipitaciones. Merms en el régimen de precipitaciones tienen un efecto directo en el crecimiento y desarrollo de cultivos o pasturas, causando una reducción de los rendimientos si se compara con años previos.

Asimismo, las técnicas espaciales derivadas del uso de imágenes provenientes de sensores montados en satélites, permiten realizar estimaciones de variables generalizadas que de otro modo sería mucho más costoso realizarlo, disminuyendo de esta manera los tiempos operativos en el muestreo y campañas de campo tradicionales (por ejemplo: humedad de suelo, clasificaciones de cultivos, etc). Esto no significa que no se deban tomar muestras de campo sino que sólo se limitarán para la validación.

Existen técnicas de aprendizaje supervisado que nos permiten resolver una función a partir de los datos de entrenamiento provistos, estas son el prelude de técnicas de “data mining” y “big data”, por lo que su uso facilita mucho resolver problemas de grandes volúmenes de datos. Algunos autores han utilizado algoritmos de Support Vector Regression (SVR) para estimar variables a nivel regional o global. Greifeneder *et al* utilizaron SVR para estimar la humedad de suelo superficial a escala global a partir de imágenes Sentinel-1 [19]. Notarnicola *et al*, en cambio, utilizaron esta metodología para analizar la retrodispersión en las bandas X, C y L como una constelación virtual en zonas agrícolas de Italia y Argentina [20]. En este trabajo utilizó el algoritmo SVR a escala local para medir la performance en la estimación de la humedad de suelo y comprobar si existe déficit hídrico que pueda afectar a los cultivos agrícolas de la zona de estudio en un año en particular.

En este sentido, la finalidad de este trabajo será correlacionar el contenido de humedad de suelo con datos obtenidos a partir de imágenes satelitales (ópticas o de radar), en el marco de la sequía registrada en la campaña agrícola 2017/18 en la zona de Bell Ville- Monte Buey. De esta manera se aplicarán todas las herramientas aprendidas en la Maestría en Aplicaciones de información espacial MAIE, sin perder de foco la formación de grado y la experiencia del trabajo en la CONAE.

### 1.1. Preguntas a responder

- ¿Es posible determinar áreas bajo sequía utilizando imágenes SAR?
- ¿Cuántas hectáreas bajo régimen de sequía hay en la zona de estudio?
- ¿Que ventajas y desventajas tiene la utilización de SAR para detección de zonas con sequía en comparación con instrumentos ópticos?

### 1.2. Objetivos

#### 1.2.1. General

El objetivo general de este trabajo es la detección y mapeo de zonas bajo régimen de sequía con imágenes ópticas y SAR.

#### 1.2.2. Específicos

En base al objetivo general planteado se desprenden los siguientes objetivos específicos:

- Estudiar las bases teóricas para la comprensión de las metodologías existentes para estimar la sequía.
- Implementar las técnicas de detección y mapeo de áreas con sequía utilizando SAR e imágenes ópticas en Argentina.
- Cuantificar la superficie agrícola que se encuentra bajo condiciones de sequía en la zona de estudio en Argentina en una ventana temporal mensual o trimestral.
- Aportar información satelital para mejorar el conocimiento sobre las características ambientales de las zonas áridas y semi-áridas aportando datos útiles para el desarrollo de las producciones agropecuarias y de industrias regionales.

### **1.3. Estructura de la tesis**


A modo de resumen se listan a continuación los ejes que se tratarán en los capítulos subsiguientes. En capítulo 2 se desarrolla el marco teórico que sustenta el estado del arte de los temas tratados en la tesis, tanto agronómicos, satelitales y estadísticos. En el capítulo 3 se describe el área de estudio, la ubicación geográfica, principales localidades, clima, actividades socio-económicas principales, etc. El capítulo 4 se listan por un lado, las imágenes satelitales, tanto ópticas como de radar que se utilizaron; los datos de campo utilizados para validación; y los principales índices de sequía utilizados en este trabajo de investigación. Por otro lado, se procede a describir minuciosamente la metodología utilizada en lo que se refiere al pre-procesamiento de las imágenes de radar, el procesamiento de los datos, el modelo SVR y finalmente se explica como se obtiene el mapa de déficit hídrico. En el capítulo 5 se exponen los resultados del análisis de sensibilidad realizados previamente a la utilización del modelo, los resultados de correr el modelo SVR y el mapa de déficit hídrico obtenido en la zona de estudio. El capítulo 6 establece las conclusiones obtenidas a partir de esta investigación. Y por último se describe los trabajos futuros o las propuestas de investigaciones futuras a partir de este aprendizaje.

#### 2.1. Teledetección

Se puede definir a la teledetección o teleobservación como la técnica que permite adquirir imágenes de la superficie terrestre desde una plataforma satelital, ya sea a partir de la energía reflejada de la luz solar o bien por la reflexión de un haz artificial emitido por el propio sensor [2].

Esta técnica involucra muchos elementos como la fuente de energía, el sistema satélite-sensor, la cubierta terrestre (suelos, vegetación y agua), el sistema receptor, el interprete y el usuario. La teledetección pasiva es aquella que utiliza la energía reflejada de la luz solar (sensores ópticos), así mismo la teledetección activa es aquella capaz de emitir un haz de energía y recibir la reflexión del mismo como es el caso del radar (aunque también existen radares pasivos) [2] [5].

Los sensores remotos obtienen información de la superficie terrestre debido a un flujo energético que proviene de la energía reflejada del objeto iluminado (por el sol o por el mismo sensor). Por lo tanto podemos describir la energía radiante según su longitud de onda (frecuencia), su dirección, su amplitud y su polarización. Según su longitud de onda el espectro electromagnético se divide en varias regiones como los rayos gamma ( $10^{-6}$ – $10^{-5}$   $\mu\text{m}$ ), rayos x ( $10^{-5}$ – $10^{-2}$   $\mu\text{m}$ ), rayos ultravioletas (0.1–0.4  $\mu\text{m}$ ), región visible (0.4–0.7  $\mu\text{m}$ ), infrarrojo (0.7–15  $\mu\text{m}$ ), microondas (1.1–100 cm), y por último las ondas de radio (>100 cm). La dirección se refiere desde donde proviene y hacia donde se dirige la onda, la amplitud tiene que ver con la magnitud de la misma y finalmente la polarización es la orientación del campo eléctrico de la energía radiante y es influenciado por la forma geométrica de los objetos bajo investigación como así también la interacción de la onda con los mismos [21].



**Figura 2.1:** Espectro Electromagnético. Se muestra desde las frecuencias más bajas (a la izquierda) hasta las frecuencias más altas (a la derecha) [22]

La imagen 2.1 presenta el espectro electromagnético describiendo la frecuencia y la longitud de onda. A la derecha se encuentran las longitudes de onda más pequeñas y las frecuencias más altas y de manera análoga hacia la izquierda aumenta la longitud de onda y disminuye la frecuencia definiendo el dominio de este espectro desde los rayos X, los rayos ultravioletas, la luz visible, los rayos infrarrojos, las microondas y por último las ondas de radio. El rango visible del espectro electromagnético es aprovechado por los sensores denominados ópticos mientras que la porción del espectro ocupado por las microondas (marcada con un recuadro naranja) es utilizado por los sensores de radar para obtener información de la superficie terrestre.

En el rango de dicho espectro existen regiones denominadas ventanas atmosféricas que permiten a los sensores remotos recavar información con la menor interferencia de la atmósfera a causa del vapor de agua, aerosoles y gases [6] [23].

La teleobservación presenta ventajas competitivas frente a la toma de datos tradicional mediante la realización de campañas de campo. Ésta permite explorar una gran cantidad de superficie terrestre en poco tiempo y relativamente a bajo costo. Los satélites permiten, a partir de su tiempo de revisita, obtener información recurrente de un punto específico del globo. De esta manera se generan un conjunto de datos sólidos que permiten la comparación de los mismos de manera coherente. Otra ventaja es la posibilidad de obtener información valiosa de lugares o regiones de difícil acceso como por ejemplo las zonas montañosas, los glaciares o los polos. Por otro lado, la teledetección permite obtener información de otras porciones del espectro electromagnético como el infrarrojo medio, térmico y las microondas que no son accesibles a la ojo humano. Por último, podemos disponer de esta información en formato digital lo que facilita su interpretación y permite su combinación con otros datos generando mapas de gran utilidad en muchos campos de la ciencia. Esto no quiere decir que las campañas de toma de datos a campo pierdan importancia, sino que se reservan para la calibración y validación de los datos obtenidos a partir de los sensores satelitales. De este

modo ocurre una sinergia que permite explorar mayor cantidad de área siendo eficientes en el uso del tiempo y los recursos [2].

## 2.2. Radar

El Radar es un sensor que se utiliza para la detección y localización por radio. Su nombre proviene de sus siglas en inglés **RA**dio **D**etection **A**nd **R**anging. Una antena Radar, montada sobre una plataforma satelital, emite una señal en el rango de las microondas que viaja a la velocidad de la luz hacia la superficie de la tierra, la señal retrodispersada o eco es captada una fracción de segundos más tarde por la misma antena, logrando calcular distancias con gran precisión [24].

Previo a la década del 50, los radares utilizados eran SLAR ("side-looking airborne radar" que significa radar aerotransportado de mirada lateral por sus siglas en inglés) comúnmente llamados Radares de Apertura Real. Estos presentan la desventaja que la resolución en azimuth disminuye a medida que se incrementa el rango. En los años siguientes esta limitación fue superada mediante el uso de un radar coherente y el principio Doppler dando lugar al Radar de apertura sintética. Éste tiene una resolución azimuthal igual a la mitad de la longitud azimuthal de la antena real siendo independiente a la distancia del rango. Esto significa que puede ser transportado por un satélite o una aeronave y la resolución en azimuth será la misma. La invención del principio SAR representó un hito fundamental para el desarrollo de sistemas de radar de imágenes aéreas y espaciales en las décadas siguientes [25].

La formación de una imagen SAR es generada a partir del cálculo del tiempo que demora un pulso en llegar a la tierra y el retorno al sensor. La señal retrodispersada con sus componentes de amplitud y fase brindan información del objeto observado. La amplitud es la magnitud del eco reflejado aportando información de la estructura y las propiedades dieléctricas del objeto. La fase, en cambio, es la posición de un punto en un momento específico en el ciclo de la onda. La intensidad del eco reflejado es el coeficiente de retrodispersión ( $\sigma_0$ ) y se expresa generalmente en decibeles (dB).

El coeficiente de retrodispersión (o backscatter coefficient en inglés) es la magnitud física en que mide el SAR. Es un número normalizado y adimensional, que compara la intensidad de la señal emitida con la intensidad recibida. Este coeficiente 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 son la geometría, la rugosidad y la constante dieléctrica [25] [23].

Una característica distintiva del Radar es su modo de observación lateral, ya que si lo hiciera hacia nadir (como lo hacen los sensores ópticos) no podría distinguir dos objetos equidistantes que se ubican uno a la derecha y otro hacia la izquierda del sensor.

Muchos lugares del mundo tienen cobertura nubosa por largos períodos de tiempo (como por ejemplo Canadá) por lo que se hace difícil obtener información con sensores ópticos. Aquí cobra gran importancia la utilización de radares que tienen su propia fuente de iluminación pudiendo observar tanto de día como de noche y, además operan en el rango de las microondas que le permite atravesar las nubes y la vegetación (con ciertas limitaciones), pudiendo obtener información de la tierra en cualquier condición climática. Estos sensores son de gran importancia en cuanto a la gestión de emergencias ya que pueden observar a través de la columna de humo y cenizas en una erupción volcánica, pueden traspasar las nubes en un ciclón o huracán, detectar desplazamientos luego de algún sismo, etc.



Como desventaja de la utilización de sistemas de radar se puede decir que, a diferencia de las imágenes adquiridas por sistemas ópticos, es necesario de un experto para el correcto procesamiento e interpretación de los datos, ya que por ejemplo podrían presentar ruido o speckle (efecto sal y pimienta), o contener distorsiones en sitios con grandes pendientes [22].

Las características más relevantes de un sensor radar son:

- Longitud de onda

El espectro electromagnético (EEM) se clasifica según su longitud de onda o su frecuencia. Asimismo las microondas ocupan una porción del espectro que va desde los milímetros hasta el metro de longitud de onda. La frecuencia de las microondas se clasifica de manera arbitraria en bandas identificadas por letras. Estas bandas fueron adoptadas por algunos de los sensores actualmente en órbita: La Banda X fue utilizada para los sensores Cosmo-SkyMed; la banda C, en sensores Sentinel-1; y la banda L, en sensores Alos Palsar y SAOCOM, etc. La longitud de onda del radar es seleccionada de acuerdo a la escala y las características del terreno que se desean identificar o estudiar [1].





Figura 2.2: Microondas en el EEM [1]

La Figura 2.2 señala el rango del EEM que ocupan las microondas y como se clasifican las bandas según su frecuencia y longitud de onda.

Analizando comparativamente las bandas se puede ver que tienen distinta penetración cuando interactúan con las superficies como vegetación, suelo seco, hielo o nieve seca. Como se observa en la Figura 2.3, a medida que la longitud de onda de la banda es mayor, la penetración de la onda en las diferentes superficies es mayor. Por ejemplo, la banda X (3 cm de longitud de onda) rebota una vez que se encuentra con el objeto o blanco sin tener penetración en el mismo. La banda L (23 cm de longitud de onda),

en cambio, puede atravesar la vegetación y hasta penetrar el suelo algunos centímetros (dependiendo de las características de la vegetación y del suelo). Una situación intermedia ocurre con la banda C (5 cm de longitud de onda).




**Figura 2.3:** Longitud de onda y penetración en el suelo y vegetación de la banda X,C y L [22]

Las señales que poseen longitud de onda mayores a 4 cm no tienen interferencia con las precipitaciones, por lo que las bandas C y L tendrán una ventaja comparativa con respecto a la banda X (a excepción de los radares meteorológicos que también operan en banda C) [1].

#### ■ Polarización

Es la forma en la que se emite y recibe la onda electromagnética del radar. Se llama co-polarización cuando se emite y recibe en el mismo plano: Puede ser HH cuando emite y recibe de forma horizontal o VV cuando emite y recibe en forma vertical como se muestra en la figura 2.4. Del mismo modo, se llama polarización cruzada cuando la onda emitida se polariza en una dirección ortogonal a la recibida, como puede ser la polarización HV o VH.

Las distintas polarizaciones nos proporcionan distintas respuestas según el objetivo o blanco. Por ejemplo, la co-polarización (HH o VV) es de utilidad para el estudio del agua en calma ya que tiene una respuesta de reflexión especular observándose en un tono oscuro; y las cros-polarizaciones o polarizaciones cruzadas posibilitan observar las vegetaciones densas o bosques.




**Figura 2.4:** Polarización de la onda electromagnética [26]

#### ■ Ángulo de incidencia

Es el ángulo formado por el haz del radar y la perpendicular a la superficie del terreno. Las interacciones de microondas con la superficie son complejas, y pueden ocurrir diferentes reflexiones en diferentes regiones angulares. Los retornos de la señal son normalmente fuertes en ángulos de baja incidencia y disminuyen al aumentar el ángulo de incidencia [24].

En la Figura 2.5 se puede observar la relación entre la intensidad de la retrodispersión y el ángulo de incidencia del radar con tres diferentes tipos de rugosidades del terreno (rugosidad baja, media y alta). El mismo muestra que a menores ángulos de incidencia, las superficies suavizadas tienen una alta retrodispersión y por el contrario cuando el ángulo de incidencia es mayor, son las superficies rugosas las que tienen mayor retrodispersión hacia el sensor.



**Figura 2.5:** Ángulo de incidencia de la onda electromagnética [22]

- Ángulo de incidencia local

El ángulo de incidencia local toma en cuenta la inclinación local de la superficie iluminada. El ángulo de incidencia local influye de forma determinante en la brillantez de la imagen [1].

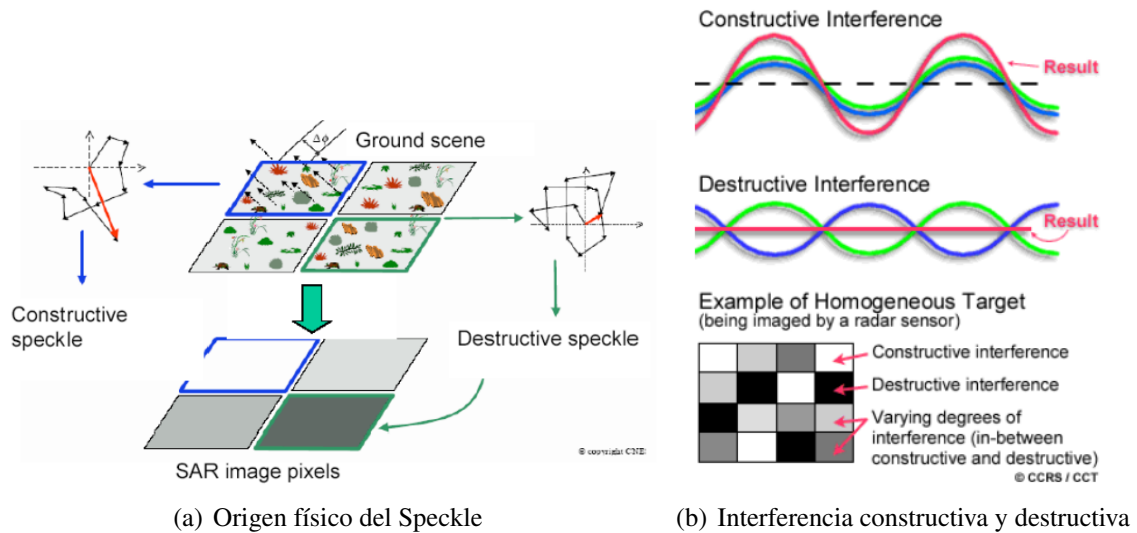
### 2.2.1. Distorsiones geométricas

La posición relativa de los objetos en la superficie terrestre, determinada por el modo de observación lateral de los sensores SAR, ocasionan distorsiones geométricas en las imágenes [1].

Las distorsiones geométricas son tres:

- Foreshortening o Acortamiento de la pendiente: ocurre cuando la cara de una montaña es observada por un sensor radar y debido a la pendiente el eco demora menor cantidad de tiempo en volver al sensor, es por ello que en la imagen se aprecia una reducción de la distancia entre la base y la cima de la montaña, en comparación con la distancia real que los separa.
- Layover o Inversión: ocurre cuando un sensor recibe anticipadamente la información de cima de un pico montañoso con respecto a su base. Layover es un caso extremo de foreshortening.
- Shadow o Sombra: como su nombre lo indica es la porción de superficie de terreno que no podemos observar debido a la obstrucción de un objeto [24].





**Figura 2.7:** Speckle: Origen y tipo de interferencia [24]

El Speckle se puede reducir por medio del Multilooking en el preprocesamiento de las imágenes o bien aplicando filtros. El multilooking es un proceso que consiste en dividir la imagen en varias miradas (o looks en inglés) y al promediar estas miradas se reduce el ruido radio-métrico. En cambio, con la aplicación de filtros se recorre la imagen con una ventana de cierta dimensión (kernel) que le aplica un calculo matemático a toda la ventana y reemplaza el valor del píxel central. De esta manera se suaviza el speckle en detrimento de la resolución espacial. Estos conceptos serán ampliados en el capítulo de materiales y métodos.

### 2.2.3. Interacción de la señal con la superficie

La onda electromagnética puede interactuar de diversas maneras con la superficie dependiendo de las características del sensor y de la naturaleza del objeto o target con el que esté interactuando [27].

#### ■ Retrodispersión de superficie (especular y difusa):

Ocurre cuando la señal radar ilumina una superficie lisa y la señal rebota en sentido opuesto al sensor, por lo que en la imagen se verá en tonos oscuros. Este es el caso del agua en calma o el pavimento. Cuando el agua no se encuentra en calma se observa el oleaje ya que parte de la señal vuelve al sensor (éste efecto se observará con diferente intensidad dependiendo del tamaño de las olas y la longitud de onda del sensor). La retrodispersión difusa, en cambio, ocurre cuando el sensor ilumina una superficie rugosa y la señal incidente se refleja en varias direcciones (Figura 2.9) [1].

Este contraste se puede ver cuando se quiere detectar derrames de petróleo, donde el agua se mueve por las olas del viento, y el petróleo al ser de gran densidad tiene menos movimiento. Como resultado, la mancha de petróleo se verá negra, mientras que el agua circundante se verá en tono de grises, dependiendo del tamaño de las olas y la longitud de onda del sensor principalmente.

#### ■ Retrodispersión doble rebote:

Este tipo de interacción de esquina se observa frecuentemente cuando la señal rebota en una superficie lisa e inmediatamente después vuelve a rebotar en algún objeto perpendicular a esta, de manera que la señal retorna casi en su totalidad hacia el sensor. Esto puede ocurrir en un edificio o un barco en el mar, observándose como un punto muy brillante en la imagen ya que retorna la señal con gran intensidad (Figura 2.9)[1].


El SAR se calibra con objetos artificiales contruidos para tal fin que simulan el efecto doble rebote llamados “reflectores tipo esquina o corners reflectors”. Estos son triédros metálicos posicionados de manera que, correctamente orientados, devuelvan toda la señal que fue enviada desde el sensor. Su estructura variará en sus dimensiones dependiendo de la banda que utiliza el SAR a calibrar. La Figura 2.8 muestra un ejemplo de corner reflector para la calibración de un sensor banda L. Asimismo los utilizados para calibración de otros satélites banda C o X son de una estructura similar pero de menor tamaño.



**Figura 2.8:** Reflectores tipo esquina o Corner Reflectors. Imagen obtenida por el EMIS en el campo experimental de la CONAE

■ Retrodispersión en volumen:

Es el resultado de la interacción múltiple de la señal del radar con numerosos objetos presentes en un medio homogéneo. Se produce, por ejemplo, en el caso de la vegetación boscosa, donde la retrodispersión es el resultado de la interacción de la onda con tallos, hojas y troncos (Figura 2.9)[1].



**Figura 2.9:** Mecanismos de Retrodispersión [22]


Los mecanismos de retrodispersión (superficie, doble rebote y en volumen) definen la “forma” de la retrodispersión mientras que la “intensidad” va a estar definido por las características dieléctricas de esa superficie. En ese sentido, si por ejemplo se observa un suelo desnudo, a medida que aumenta la rugosidad aumentará la retrodispersión pero a su vez a medida que la humedad del suelo va en incremento, la retrodispersión también aumentará en intensidad.

## 2.3. Relación Agua- Suelo- Planta

La cantidad total de agua que existe en el planeta se mantiene prácticamente constante, sólo que va cambiando de estado (sólido, líquido o gaseoso). El vapor de agua se condensa al enfriarse y provoca las precipitaciones. El agua, proveniente de las nevadas o lluvias, puede escurrir por la superficie hacia los ríos y lagos, o bien puede infiltrarse en el suelo quedando disponibles para las plantas o cultivos. Parte del agua que se infiltra, no puede ser retenida en los suelos y percola profundamente aportando al volumen de las aguas sub-superficiales. A su vez estas aguas subterráneas tienen un movimiento lateral y se mueven a través de la pendiente hacia lagos y ríos. Por otro lado, el agua que se encuentra en el suelo puede evaporarse desde la superficie del mismo o ser transpirada por las plantas. Esta evaporación del agua desde la superficie de las plantas, del suelo o de las mismas fuentes de agua aportan a la masa de vapor de agua que recargan las nubes para una nueva precipitación y renuevan el ciclo del agua [28].

El agua contenida en el suelo es solo el 0.05 % de los recursos de agua del planeta, pero juegan un papel muy importante en los ciclos del agua, de la energía y del carbono en la climatología y la meteorología.

El suelo es un sistema disperso en el que se diferencian tres fases: la fase sólida, compuesta por agregados minerales y orgánicos; la fase líquida, compuesta por la solución del suelo; y la fase gaseosa compuesta por aire que se ubica dentro de los poros del suelo. En volumen, la fase sólida ocupa aproximadamente el 50% del total, mientras que las fases gaseosa y líquida se reparten el resto del espacio disponible [29].



**Figura 2.10:** Fases del suelo [29]

La Figura 2.10 muestra un perfil de suelo y ampliando sobre la capa superficial, se indica la parte sólida, líquida y gaseosa del suelo.



Los métodos e instrumentos que se utilizan para determinar la humedad del suelo se dividen en dos grupos:

- métodos basados en la determinación del contenido de agua del suelo.
- métodos que miden el potencial de agua del suelo.

El contenido de agua del suelo es expresado como una relación entre la masa de agua contenida en una muestra de suelo y la masa seca de la muestra de suelo o el volumen original de la muestra. Estas dos expresiones están linealmente relacionadas por un coeficiente conocido como la densidad aparente del suelo muestreado

El agua en el suelo esta retenida por varias fuerzas: entre ellas la gravedad de la tierra, los solutos disueltos en el agua misma del suelo y la tensión superficial en la interfase sólido-líquida. Estas fuerzas, actuando sobre el agua del suelo, son la causa de que la misma sea adsorbida, retenida, transferida, drenada, evaporada o transpirada. La fuerza con que el agua es retenida por el suelo depende del contenido hídrico del suelo, y mientras más seco se encuentre ese suelo, mayor será la cantidad de trabajo necesario para extraerla. A este trabajo se lo denomina potencial hídrico. El potencial hídrico es la sumatoria de las fuerzas que ejercen estos potenciales parciales del suelo como indica la siguiente ecuación (2.1):

$$\Psi_t = \Psi_g + \Psi_m + \Psi_o + \Psi_p \quad (2.1)$$

Donde el potencial total es igual al pot. gravitatorio + pot. mátrico + pot. osmótico + pot. de presión; y las unidades de medida de estos son en milímetros de mercurio, kilo Pascales, mega Pascales, bares o en metros de columna de agua.

El potencial mátrico es el más importante de los componentes del potencial total y responde a las fuerzas de atracción del agua por la superficie de las partículas sólidas del suelo, y a las fuerzas de atracción molecular entre las propias moléculas del agua. El conjunto de estos dos tipos de fuerzas hace que el agua sea retenida por adsorción (por la matriz del suelo) y por capilaridad (por las mismas moléculas de agua) en suelos con un contenido hídrico por debajo del nivel de saturación.

El potencial gravitatorio es la parte del potencial total que se debe a la fuerza de la gravedad y su valor será positivo o negativo dependiendo de la altura a la que se sitúa el nivel de referencia. Para alturas de referencia superiores al punto considerado, los potenciales serán negativos, en caso contrario serán positivos.

El potencial presión es la parte del potencial total que se explica por la existencia de presiones distintas a las del punto de referencia, como por ejemplo ocurre en los suelos saturados, por la presión de la columna de agua. Si el punto en cuestión está por debajo del nivel freático,  $\Psi_p$  es positivo, mientras que en suelos no saturados se considera nulo.

El potencial osmótico resulta de las fuerzas de atracción que ejercen los solutos (sales) sobre las moléculas del solvente. El potencial osmótico siempre tiene valores negativos, ya que el agua fluiría espontáneamente desde un depósito de agua pura hasta otro con solución similar a la del suelo.

Desde el punto de vista de la extracción del agua por la planta, más que el contenido de humedad interesa conocer la energía con que el agua es retenida. De nada sirve que un suelo contenga agua abundante, como es el caso de los suelos salinos, si las raíces de los cultivos no tienen la fuerza de succión necesaria para extraerla [30].

Existen métodos directos e indirectos para cuantificar la cantidad de agua contenida en el suelo:

- Directos: El método gravimétrico es el único método directo de medición de la humedad del suelo. Este método consiste en extraer una muestra de suelo con un volumen conocido, se toma el peso húmedo de la muestra, se lleva a estufa por 24 horas a 105°C y luego de secada la muestra hasta peso constante se obtiene el peso seco. Una vez que se registran los valores de peso húmedo y peso seco, se puede calcular la humedad gravimétrica o volumétrica como se muestra en las siguientes Ecuaciones 2.2 y 2.3 respectivamente.

$$Humedad_{Grav} = \frac{Peso_{humedo} - Peso_{seco}}{Peso_{seco}} * 100 \quad (2.2)$$

$$Humedad_{Volum} = \frac{Peso_{humedo} - Peso_{seco}}{Peso_{seco}} * Dap * 100 \quad (2.3)$$

Donde Dap es la densidad aparente del suelo considerado.

El método gravimétrico es el más exacto para medir el contenido de humedad del suelo y resulta necesario para calibrar el equipo utilizado en los demás métodos. Sin embargo, no puede usarse para obtener un registro continuo de la humedad del suelo de un lugar determinado, ya que el agua que penetra por los orificios que quedan como consecuencia de la extracción de muestras, suele alterar el contenido hídrico de las capas adyacentes al mismo cuando se produce una lluvia [30].

- Indirectos: Miden alguna característica asociada al contenido de humedad en el suelo, como por ejemplo el valor del potencial mátrico, la dispersión de neutrones, o la constante dieléctrica del agua.

Los sensores de Capacitancia se utilizan para medir la constante dieléctrica del suelo y a partir de ésta se calcula la humedad de suelo dependiendo del tipo de suelo.

La mayoría de los materiales del suelo tienen una constante dieléctrica que varía entre 2 y 4, mientras que la constante dieléctrica del agua es de 80. Por lo tanto, a medida de que el contenido hídrico del suelo aumenta, la constante dieléctrica también lo hace.

La sonda tiene una cierta frecuencia de resonancia, y a medida de que la humedad aumenta (la constante dieléctrica aumenta) la frecuencia de resonancia se eleva. La unidad de control monitorea esta elevación de frecuencia y hace una correlación para determinar el contenido de humedad basado en la elevación de la frecuencia [30].


El método utilizado por Equipo de Medición in Situ (EMIS) de la CONAE es el de Capacitancia. Estos sensores son de la marca Stevens modelo Hydra Probe II que se describirá en el capítulo de materiales y métodos. Aunque también se utiliza el método directo para hacer la calibración de los sensores [31].

Las constantes hídricas muestran la relación que existe entre plantas, el agua y el suelo. Estas son:

- Saturación: Se refiere al contenido de agua del suelo en el que todos los poros están llenos de agua. En los suelos bien drenados es un estado temporario ya que el exceso de agua es drenada por efecto de la gravedad en los poros de mayor tamaño para ser reemplazada inmediatamente por aire.

- **Capacidad de Campo:** Es la máxima cantidad de agua que puede contener un suelo luego de transcurridos dos días de una precipitación o riego, es decir cuando ha percolado el agua gravitacional a las capas sub-superficiales.
- **Capacidad de Marchitez Permanente:** es cuando las raíces de las plantas no tienen la fuerza necesaria para continuar extrayendo agua del suelo. Es decir que la fuerza de atracción del agua con el suelo es mayor a la capacidad de succión de las raíces. El punto de marchitez depende de la textura y la porosidad, y, por lo tanto, es diferente para cada tipo de suelo .

La diferencia entre el contenido de agua en capacidad de campo y el de capacidad de marchitez permanente es lo que se denomina “Agua útil”. Es el agua que se encuentra disponible para la absorción de las plantas [28] [29]. En la Figura 2.11 se muestra la relación entre el contenido de agua en el suelo y la textura. El contenido de humedad de suelo en capacidad de campo aumenta a medida que disminuye la textura del suelo al igual que el punto de marchitez permanente, pero el agua disponible para las plantas es cada vez mayor. Los suelos arenosos o de textura gruesa tienen poca capacidad de retener agua mientras que los suelos arcillosos o de textura fina retienen gran cantidad de agua y gran parte de esa agua se encontrará disponible para las plantas. Como se observa en la figura, se distinguen dos rangos de agua útil. Estos son: el agua fácilmente disponible y el agua lentamente disponible. A medida que disminuye la cantidad de humedad en el suelo, el agua será retenida más fuertemente a la matriz del suelo y será más difícil de extraerla, hasta que llega a un punto que no tiene la fuerza necesaria para extraerla [30].



**Figura 2.11:** Agua disponible para las plantas según la textura del suelo [32]

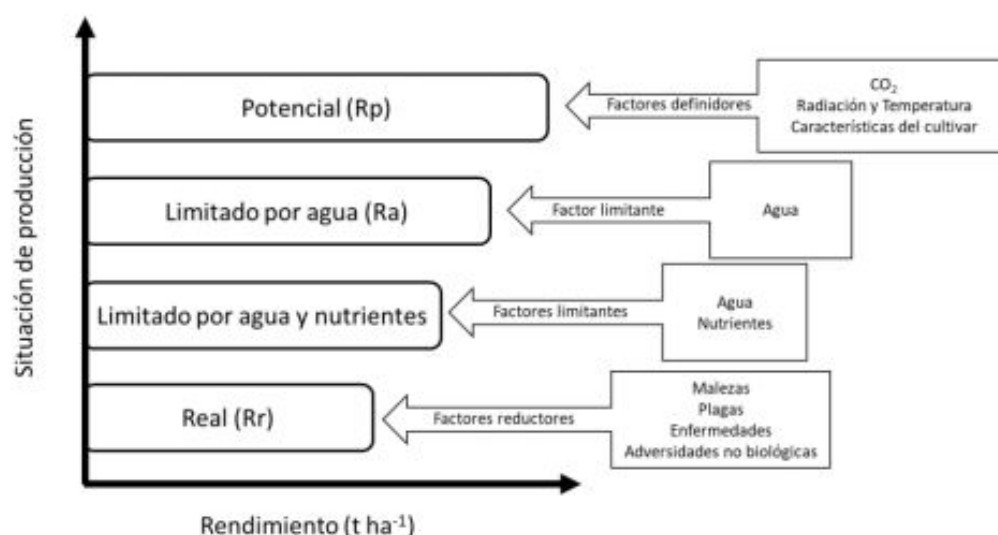
## 2.4. Cultivos

En la zona de estudio, los principales cultivos de verano son el maíz y la soja, mientras que en invierno el cultivo más sembrado es el trigo. El sistema de siembra predominante es la siembra directa, es decir sin remoción del suelo, conservando la estructura y el agua en el suelo.

Resulta importante la aclaración semántica que un “cultivo de primera” es aquel que se siembra en verano sin haber tenido un antecesor de invierno, mientras que un “cultivo de segunda” es aquel que sí tuvo un antecesor de invierno.

Los cultivos tienen una fecha óptima de siembra dependiendo de la disponibilidad de las necesidades del cultivar en cuanto a radiación, temperaturas y agua principalmente para alcanzar el rendimiento potencial. Es por ello que los cultivos se denominan como “tempranos” o “tardíos” según su época de siembra. Por ejemplo, un maíz temprano en esta zona se siembra en septiembre mientras que los tardíos se siembran en diciembre. Esto es posible siempre y cuando se tengan en cuenta los requerimientos climáticos de la planta y no se perjudique el cultivo. Si se adelanta o atrasa demasiado la siembra las etapas de desarrollo se verían afectadas por las condiciones ambientales al finalizar el ciclo. Por ejemplo esto puede ocurrir debido a heladas tempranas o tardías.

El rendimiento es una variable que depende de muchos factores. Es por ello que se diferencia el Rendimiento potencial ( $R_p$ ), el limitado por agua ( $R_a$ ), el limitado por agua y nutrientes, y el rendimiento real ( $R_r$ ). El  $R_p$  es la producción máxima de un cultivo es decir que no tuvo limitación alguna, es decir que logró interceptar la mayor cantidad de radiación posible en las etapas críticas de crecimiento y desarrollo, en un rango de temperatura óptima para lograr expresar el potencial genético del cultivar en un ambiente determinado. Del mismo modo se dice que el  $R_a$  es aquel que muestra una merma en la producción debido al tipo de suelo y el régimen de precipitaciones de la zona de estudio, pero sin limitaciones de nutrientes ni por ataques de plagas y/o enfermedades. El rendimiento limitado por agua y por nutrientes muestra una disminución de la producción debido al tipo de suelo, al régimen de precipitaciones y a los nutrientes disponibles en el suelo, pero sin ataques de plagas y/o enfermedades. Por último  $R_r$  es aquel que logró un productor agropecuario con un manejo determinado con limitaciones ambientales, de agua, nutrientes, plagas y enfermedades. A medida que avanzan las limitaciones se habla de un tipo de rendimiento distinto y se espera una producción menor [10] [33]. Por lo tanto, las prácticas de manejo de un productor deberían estar orientadas a maximizar el rendimiento, sembrando el cultivar mejor adaptado a la zona (factor definidor), minimizando el impacto de plagas, malezas y enfermedades (factores reduccionistas), y cuidando a máximo el agua de las precipitaciones (factor limitante). Estas son medidas o decisiones que toma el productor para acortar la brecha entre el  $R_r$  y el  $R_p$ , buscando el rendimiento máximo alcanzable. El rendimiento potencial del maíz en secano en Argentina a nivel nacional es de 116 qq/ha, mientras que el rendimiento promedio es de 68 qq/ha [34]. Un estudio de INTA (realizados en el sudeste de Córdoba) revela que, en condiciones de secano, los rendimientos de maíz temprano y tardío podrían incrementarse en alrededor de 39 y 56 % respectivamente [33]. Esto indica que todavía los rendimientos alcanzables están muy por debajo de los  $R_p$ .




**Figura 2.12:** Situación de Rendimiento de un cultivo: Rendimiento potencial (Rp), Rendimiento limitado por agua (Ra), Rendimiento limitado por agua y nutrientes, Rendimiento Real (Rr) [33] adaptado de [10]

La Figura 2.12 se describen los tipos de rendimiento de un cultivo en base a los factores definidores, limitantes o reductores que determinan la producción final.

En etapas iniciales de un cultivo, el agua de un lote se pierde por evaporación en mayor medida y por la evapotranspiración del cultivo en menor medida ya que el cultivo aún no ha logrado cubrir el surco. Pero a medida que el cultivo crece y se desarrolla, los órganos vegetales van cubriendo la superficie del suelo y el agua que se consume se transforma en vapor de agua a partir de la evapotranspiración en un gran porcentaje, reduciendo la evaporación directa del suelo. Consecuentemente la evapotranspiración del cultivo esta estrechamente ligada a la demanda atmosférica.

El INTA, en un trabajo de investigación realizado por Andreani *et al*, muestra el consumo de agua de los cultivos extensivos sin limitaciones en la Pampa Húmeda (ver Figura 2.13). El maíz y la soja de primera fueron los que más consumo mostraron, con valores de 550 y 535 mm respectivamente, y el trigo y la soja de segunda mostraron valores más bajos de 430 y 435 mm respectivamente [35].



**Figura 2.13:** Consumo de agua promedio acumulado durante el ciclo de cultivos de Maíz, Trigo, Soja 1ª y Soja 2ª en el sur de la Provincia de Santa Fe [35]


#### 3.1. Información general

El área de estudio corresponde a una superficie de  $100\text{ km}^2$  (equivalente a una superficie de 1 millón de hectáreas) alrededor de las localidades de Bell Ville, Justiniano Posse y Monte Buey en la Provincia de Córdoba. Esta zona comprende fragmentos de los departamentos San Martín, Unión y Marcos Juárez. Estos comparten características geográficas y fisonómicas similares por lo que se procederá de aquí en adelante a considerarla como una región homogénea.

Bell Ville (ciudad cabecera del departamento Unión) se encuentra ubicada en la Pampa Húmeda, a orillas del río Tercero, a 60 kilómetros al sudeste de Villa María, en el cruce de la Ruta Nacional N° 9 y la ruta provincial N° 3 con el importante ramal ferroviario de trocha ancha que une a la ciudad de Córdoba con la de Buenos Aires, pasando por Rosario. Su posición es equidistante de las dos ciudades más importantes de la Ruta 9, pues está a 200 kilómetros al sudeste de la ciudad de Córdoba y 200 kilómetros al noroeste de Rosario.

Es una zona mayormente agrícola-ganadera e industrial. En cuanto a la agricultura los principales cultivos son soja, maíz y trigo y en cuanto a la industria los principales rubros son la producción de alimentos y maquinaria agrícola. Las estimaciones agrícolas del Ministerio de Agricultura, Ganadería y Pesca MAGyP de la Presidencia de la Nación muestran que en la campaña 2017/18 en el departamento Unión se sembraron 466.540 ha. de soja con un rendimiento promedio de 32 quintales por ha., 245.620 ha. de maíz con un rendimiento promedio de 84 quintales por ha. y 194.155 ha. de trigo con un rendimiento promedio de 45 quintales por ha. siendo estos 3 los principales cultivos agrícolas de la zona [36].

En la Figura 3.1 se observa la provincia de Córdoba en la proyección cartográfica WGS 84. Al sureste de la provincia se encuentra demarcada el área considerada para este estudio.



**Figura 3.1:** Área de estudio en Argentina: Bell Ville- Monte Buey, Córdoba (proyección WGS 84) [37]




## 3.2. Clima

### 3.2.1. Régimen térmico

Bell Ville tiene un clima templado registrando temperaturas medias mensuales de  $23.9^{\circ}\text{C}$  en verano y  $9.5^{\circ}\text{C}$  en invierno y una amplitud anual de  $14.4^{\circ}\text{C}$ . La distribución pluviométrica es de un régimen monzónico ya que las precipitaciones se concentran en la estación cálida.

La fecha promedio de ocurrencia de heladas es el 22 de mayo para las tempranas y el 9 de septiembre para las tardías, siendo el periodo libre de heladas de 255 días [38].


En la Figura 3.2 se observan las temperaturas medias mensuales históricas en puntos rojos unidos por una línea del mismo color marcando la tendencia anual. Las barras azules muestran las precipitaciones medias mensuales históricas con una tendencia estival siendo los meses de noviembre a marzo los que registran mayores precipitaciones medias mensuales.



**Figura 3.2:** Precipitación y Temperatura media mensual, Bell Ville, Córdoba [38]

### 3.2.2. Régimen hídrico

La Figura 3.3 presenta el balance hídrico climático. Aquí se puede observar en azul, la evapotranspiración potencial (ETP) y en naranja, la evapotranspiración real (ETR). La diferencia entre ellas nos permite inferir los periodos en los que existen excesos o déficit hídricos. Consecuentemente podemos decir que el área de estudio presenta un balance hídrico negativo a excepción del final del verano y comienzo del otoño, por lo que resulta crítico como decisiones de manejo agronómico todas aquellas prácticas que incidan sobre el manejo del agua en el suelo [38].

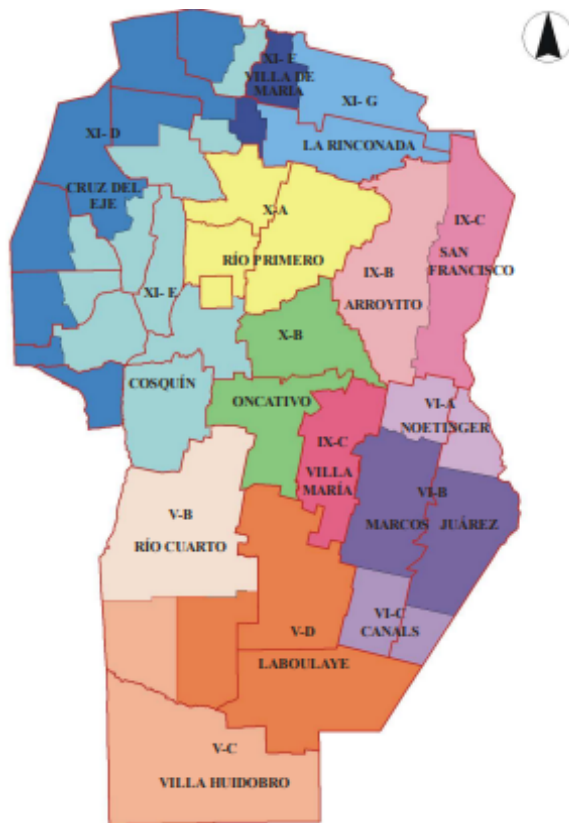


**Figura 3.3:** Balance Hídrico Climático, Bell Ville, Córdoba [38]



### 3.3. Suelos

La Provincia de Córdoba se encuentra dividida en 15 Zonas Agro-económicas Homogéneas (ZAHs), entendiéndose por tales a unidades territoriales que mantienen cierta homogeneidad en sus características ambientales, estructurales, socio-económicas, productivas e institucionales. El área de estudio se encuentra enclavada dentro de dos de ellas por lo que se diferenciarán en sus tipos de suelos y relieves por sobre todas sus características (ver Figura 3.4).



**Figura 3.4:** Zonas Agro-económicas Homogéneas (ZAHs) de la Provincia de Córdoba [39]

- **ZAHs VI-A NOETINGER**

En esta zona son importantes los suelos desarrollados en condiciones de hidromorfismo y tienen un drenaje pobre como los Natracualfes y Natralboles que comúnmente se encuentran en los campos bajos, sobre todo en las proximidades de la depresión del arroyo Tortugas. En las lomas se encuentran suelos Argiudoles típicos y ácuicos, y a medida que disminuyen las precipitaciones cambian a Argiustoles údicos. El riesgo de erosión de los suelos se da por causas eólicas, manifestando una situación grave tierras que representan el 12 % de la superficie provincial.

- **ZAHs VI-B MARCOS JUÁREZ**

Aquí se pueden encontrar suelos desarrollados sobre sedimentos eólicos, franco limoso fino. Esta región se caracteriza por sus suelos de gran desarrollo, fertilidad y alta productividad, consecuencia de sus caracteres físico químicos intrínsecos y del régimen de precipitaciones que los hace los suelos tradicionalmente de mayor productividad de la provincia. Los suelos zonales son predominantemente Molisoles, profundos, con un horizonte superior oscuro rico en materia orgánica y bien estructurado que facilita el

movimiento superficial del aire y el agua. Son Argiudoles (44 %), Hapludoles (10 %) y Haplustoles (34 %) en las lomas; en los bajos son Natracualfes (3 %) y Natralboles (5 %) [39].

Estos nombres de los suelos provienen de la clasificación taxonómica del USDA(1999). Esta clasificación señala las características más importantes de la morfología de los suelos, y propone un esquema para predecir y evaluar el tipo e intensidad de las limitaciones que determina su capacidad productiva. En la misma podemos clasificar los suelos según Ordenes, Subórdenes, Grandes grupos, Subgrupos, Familias y Series.

En la Figura 3.5 se muestran como se clasifican los suelos del departamento Unión de la provincia de Córdoba, la superficie que ocupan en el departamento y el porcentaje (%) del mismo. La clasificación incluye hasta Subgrupo, es decir que abarca Orden, Suborden, Gran grupo y Subgrupo. Aquí se observa que el suelo más predominante en el departamento Unión es el Haplustol údico ocupando el 31.91 % de la superficie y en segundo lugar se encuentra el Haplustol éntico que ocupa el 13.65 % de la superficie del departamento Unión.

**Haplustol údico:** Son suelos profundos, bien drenados, con el horizonte superior o capa arable oscura, bien provista de materia orgánica, buena fertilidad natural y estructura moderada (epipedón mólico). El horizonte subsuperficial está algo alterado y moderadamente enriquecido en arcilla iluvial (horizonte cámbico) y desarrollado bajo condiciones ústicas de humedad transicional al údico (condiciones climáticas subhúmedas).

Han evolucionado a partir de sedimentos eólicos franco arenosos, francos y franco limosos, dependiendo de la ubicación geográfica en que se encuentren.

Son suelos agrícolas de muy buena productividad, aptos para una amplia gama de cultivos.

**Haplustol éntico:** La característica principal de este suelo es la presencia de un horizonte superficial oscuro, con moderado contenido de materia orgánica y bien estructurado (epipedón mólico), seguido de un horizonte de transición (AC) con escaso desarrollo y poco alterado, pasando gradualmente al material originario, constituyendo un suelo poco evolucionado, de características énticas, que se diferencia de los Haplustoles típicos que presentan un horizonte con acumulación de arcillas iluviadas (horizonte B). Por lo tanto, la secuencia de horizontes de este subgrupo es A, AC y C; presentan además buen drenaje con napas freáticas profundas que no afectan el perfil de suelo. Estos suelos se desarrollan en condiciones climáticas de aridez (régimen ústico de humedad).

Estos suelos por lo general son de granulometría variada, desde franco arenosos, francos a franco limosos.

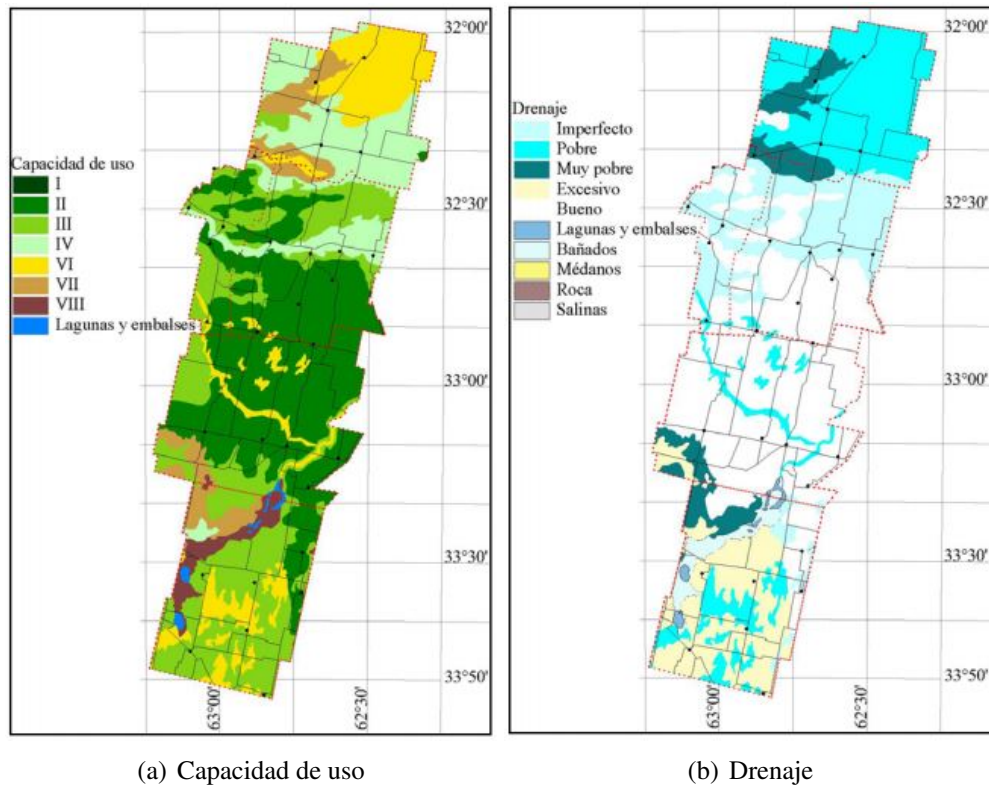
En general son suelos agrícolas que presentan limitaciones climáticas desde moderadas a severas, según su ubicación geográfica, teniendo incidencia directa en la producción, la granulometría de los materiales. En los franco arenosos, el problema de baja retención de agua se acentúa el déficit hídrico; y en los franco limoso, los suelos pueden “plancharse” por alta intensidad de laboreos.

Por otro lado, los suelos se clasifican según su capacidad de uso. Estas clases van del I al VIII e indican progresivamente las limitaciones que presentan los suelos. Las clases desde I a IV son aptas para la agricultura; las clases desde V a VII son aptas para pasturas destinadas a la ganadería o bien para forestación; y por último la clase VIII no es apta para cultivos, pasturas o forestación alguna. En la Figura 3.6 de la izquierda, se muestran las áreas que ocupa cada clase según su capacidad de uso, siendo la clase II la que mayor cantidad de superficie ocupa (en verde oscuro) en el departamento Unión. El 41.6 % (correspondiente a 394.000 ha) del

ORDEN	SUBORDEN	Gran Grupo	Subgrupo	miles/ha	% Departamento
ALFISOL	ACUALF	Albacualf		63	5.95
				63	5.95
			típico	8	0.79
				8	0.79
			Natracualf	54	5.16
			típico	48	4.52
		mólico	7	0.64	
MOLISOL	ALBOL	Argialbol		894	84.67
				160	15.19
				53	5.03
			típico	53	5.03
			Natralbol	107	10.16
			típico	107	10.16
	ACUOL	Argiacuol		69	6.51
				4	0.35
			típico	4	0.35
			Endoacuol	20	1.87
			típico (calcárea)	13	1.21
			típico	7	0.66
			Duracuol	35	3.32
			nátrico	35	3.32
			Natracuol	10	0.98
			típico	10	0.98
			USTOL	Argiustol	
		47			4.46
	ácuico	8			0.78
	údico	39			3.68
	Haplustol			523	49.51
		típico		13	1.24
		ácuico		2	0.20
		éntico		144	13.65
		thaptoárgico		7	0.69
		údico		337	31.91
		udorthéntico		18	1.68
		fluvéntico		2	0.14
	Natrustol			8	0.72
		típico		8	0.72
	UDOL	Argiudol		88	8.29
				79	7.48
		típico	79	7.48	
		Hapludol		9	0.81
			típico	9	0.81
	Suelos sin diferenciar				68
Misceláneas				31	
	Bañados			29	
	Lagunas			2	

Figura 3.5: Taxonomía hasta el nivel de Subgrupo del Departamento Unión [38]

departamento pertenece a esta clase considerándose un suelo de gran capacidad productiva para los cultivos[38]. A la derecha se observa la clasificación del suelo en función del drenaje. Se puede ver que los suelos de pobre drenaje coinciden con suelos clase VI o superior marcando la limitación de los mismos.



**Figura 3.6:** Capacidad de uso de los suelos y drenaje del departamento Unión [38]

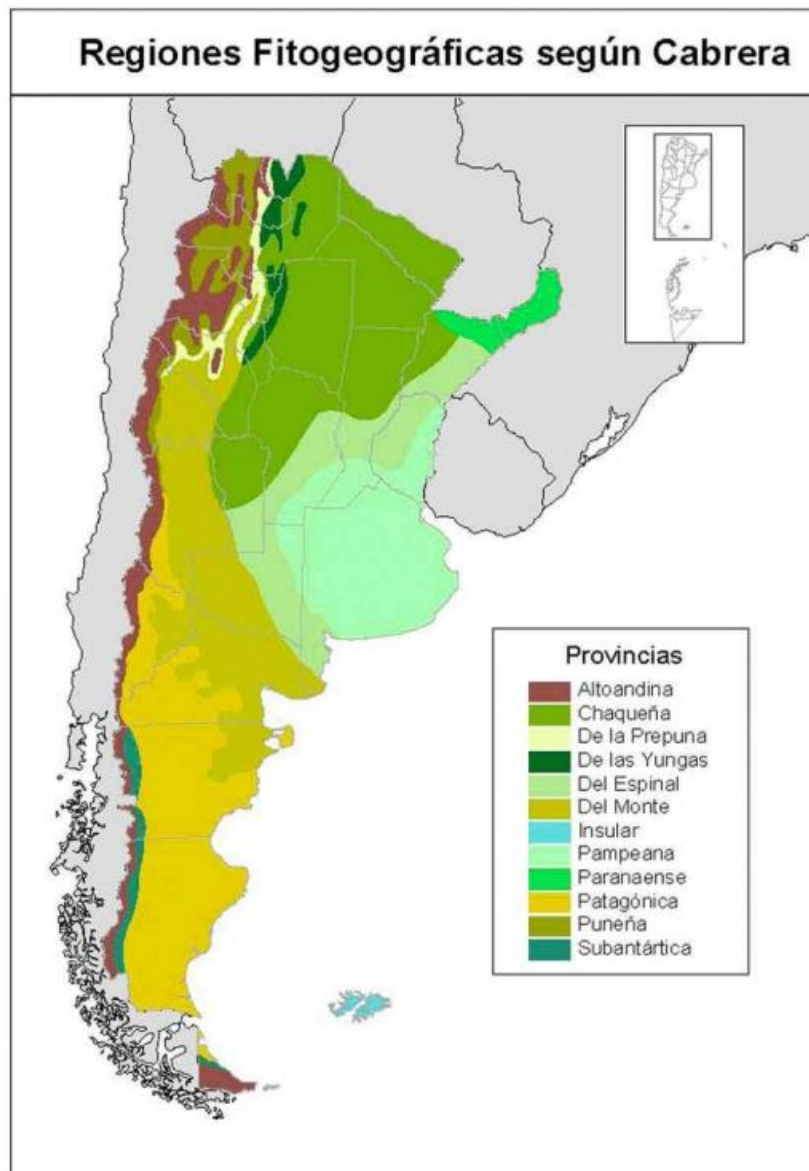
## 3.4. Vegetación

Desde el punto de vista fitogeográfico, la provincia de Córdoba presenta tres regiones:

- Provincia Fitogeográfica Pampeana (Pampa),
- Provincia Fitogeográfica Del Espinal (Espinal),
- Provincia Fitogeográfica del Chaco -Distrito Oriental (Chaco Oriental)

El área de estudio se encuentra ubicada dentro de la primera aunque los límites no son estrictos sino que presentan una transición entre ésta y la región del Espinal. La región fitogeográfica Pampeana es una estepa que presenta dos períodos de descanso para la vegetación: uno de ellos ocurre en el invierno debido a las bajas temperaturas; y el otro ocurre en el verano donde la demanda atmosférica es elevada debido a las altas temperaturas y a la ocurrencia de sequías. La vegetación natural dominante está constituida por hierbas, en especial gramíneas como cebadilla criolla, flechilla, pasto puna y cortadera. Esta vegetación prístina sólo persiste junto a las vías férreas o en algunos campos abandonados durante muchos años[40].

En la Estepa o Pseudoestepa de Gramíneas los Hemicriptófitos cespitosos son las especies más comunes. Son matas densas que se secan durante el invierno o la estación seca, dejando



**Figura 3.7:** Regiones Fitogeográficas de la República Argentina [40]

los renuevos protegidos por el tejido muerto o seco. Cuando los inviernos no son muy fríos, o los veranos son lluviosos, el período vegetativo de las Gramíneas perennes no sufre interrupción y los renuevos pueden desarrollarse antes que mueran las cañas del período anterior. En esos casos la Estepa funciona como Pradera (si sólo hay descanso invernal) o como Sabana (cuando sólo hay descanso estival), de ahí la denominación de Pseudoestepa [40].

Tradicionalmente la actividad predominante fue la ganadería extensiva seguida por la agricultura; pero en las últimas décadas ha ocurrido un avance de las fronteras agrícolas relegando a la ganadería a zonas marginales. Esto produjo una fuerte agriculturización de la zona, con una gran participación del cultivo de soja aumentando la superficie sembrada en un 464 % desde el año 1980 al 2000 [39].

Las figuras 3.8 y 3.9 muestran la evolución de los principales cultivos del departamento Unión. En la campaña 1995-96 se sembraron 226.000 ha de soja y 15 años después se registró máximo valor en superficie sembrada siendo de 558.050 ha. Analizando los casos de maíz y trigo en la campaña 2018-19 se registraron los máximos valores en superficie sembrada siendo de 182.761 y 187.650 ha respectivamente. En otro orden de importancia en cuanto al área sembrada que ocupan en el departamento se encuentra el maní y el sorgo. El maní registró la mayor superficie sembrada en la campaña 2018-19 llegando a superar las 10.000 ha y, por otro lado, el sorgo fue perdiendo hectáreas desde la campaña 1999-2000 hasta la actualidad pasando de 13.500 ha a sólo 1595 ha. En todos los cultivos se registran año a año rendimientos superiores (en toneladas por hectárea sembrada) debido principalmente al mejoramiento genético de los cultivares [41].





Figura 3.8: Superficie principales cultivos del departamento Unión [41]

Año	Soja		Maiz		Maní		Sorgo		Trigo	
	Superficie	Producción	Superficie	Producción	Superficie	Producción	Superficie	Producción	Superficie	Producción
1995-1996	226000	451000	20200	80800	500	950	12000	70200	95000	142500
1999-2000	420000	993000	47000	333700	1500	1800	13500	66200	137000	424700
2005-2006	554900	1549052	101500	771400	750	1500	1700	8500	130900	340340
2009-2010	558050	1782475	95500	1040950	150	375	4950	25740	27520	58940
2015-2016	481364	1810613	121330	1055571	8600	31820	7600	34200	81320	276490
2018-2019	407533	1604716	182761	1754505	10322	34063	1595	7337	187650	525420

Figura 3.9: Evolución del área (ha-1) y producción (tn) de los principales cultivos del departamento Unión [41]

El crecimiento de la superficie de soja desde la campaña 1995-96 hasta 2009-10, pasando de una producción de soja de 226.000 ha en la campaña 1995-96 a 558.050 ha en la campaña 2009-10, se debe fundamentalmente al avance de la agricultura en detrimento de la ganadería. Esto se puede observar en la Figura 3.10 donde se evidencia el retroceso de la crianza los animales ya que en 1995-96 había un porcentaje en superficie ocupada por ganadería cercano al 70% mientras que en agricultura era menor al 30%. En la actualidad esa relación se encuentra invertida.



**Figura 3.10:** Superficie cultivos vs. ganadería en el departamento Unión [41]

---

### Materiales y Métodos

---

#### 4.1. Materiales

Para el desarrollo de esta investigación se recopiló y se construyó información derivada de sensores remotos, datos climáticos, y mediciones de campo, se listan a continuación:

- Imágenes SAR: Sentinel-1,
- Imágenes ópticas: Sentinel-2,
- Datos de Humedad de suelo: Red telemétrica da la misión SAOCOM,
- Datos Climatológicos: Estación meteorológica del IPEA 293 en Bell Ville; y Serie histórica plataforma WorldClim,
- Índices de sequía: PDSI y VCI.

##### 4.1.1. Imágenes SAR: Sentinel-1

La misión Sentinel-1 es una constelación de 2 satélites polares (1A y 1B) que transportan sensores SAR banda C adquiriendo imágenes tanto de día como de noche y en cualquier condición climática. El satélite Sentinel-1A fue lanzado el 3 de abril del 2014 y el Sentinel-1B el 25 de abril del 2016 [42].


Este sensor presenta distintos modos de observación que determinan diferentes resoluciones espaciales, ancho de barrido y ángulos de incidencia, al observar una porción de la tierra (Figura 4.1) [43].

Los modos de observación de Sentinel-1 son:

- Interferometric Wide Swath Mode (IW): Es el modo de adquisición principal sobre tierra y tiene un ancho de escena de 250 km. El Modo IW captura tres sub-franjas utilizando la observación de terreno con escaneos progresivos SAR.



- **Strip Map Mode (SM):** Este modo se utiliza principalmente para observar pequeñas islas o excepcionalmente para la gestión de emergencias. Proporciona datos con una franja de 80 km.
- **Extra Wide Swath Mode (EW):** Este modo se emplea sobre zonas marítimas y polares en aplicaciones para el tráfico de barcos, el derrame de petróleo y el monitoreo de hielo marino donde se necesita una gran cobertura y tiempos de revisita cortos. El ancho de escena en este modo es de 400km.
- **Wave Mode (WV):** Este modo pretende ayudar en la determinación de la dirección y altura de olas en el océano. Se adquieren alternativamente con dos ángulos de incidencia cada 100 km, es decir, dos imágenes con el mismo ángulo de incidencia están separadas 200 km.



**Figura 4.1:** Sentinel-1: Modos de Adquisición [43].

Los productos adquiridos por Sentinel -1 se dividen también según el nivel de procesamiento:

- **Nivel 0:** Consisten en una secuencia de datos crudos SAR no enfocados. Para que los datos sean utilizables, será necesario descomprimirlos y trabajarlos con un procesador SAR.
- **Nivel 1:** Son los productos generalmente disponibles y destinados a la mayoría de los usuarios de datos. Estos son los productos Single Look Complex (SLC) y Ground Range Detected (GRD).

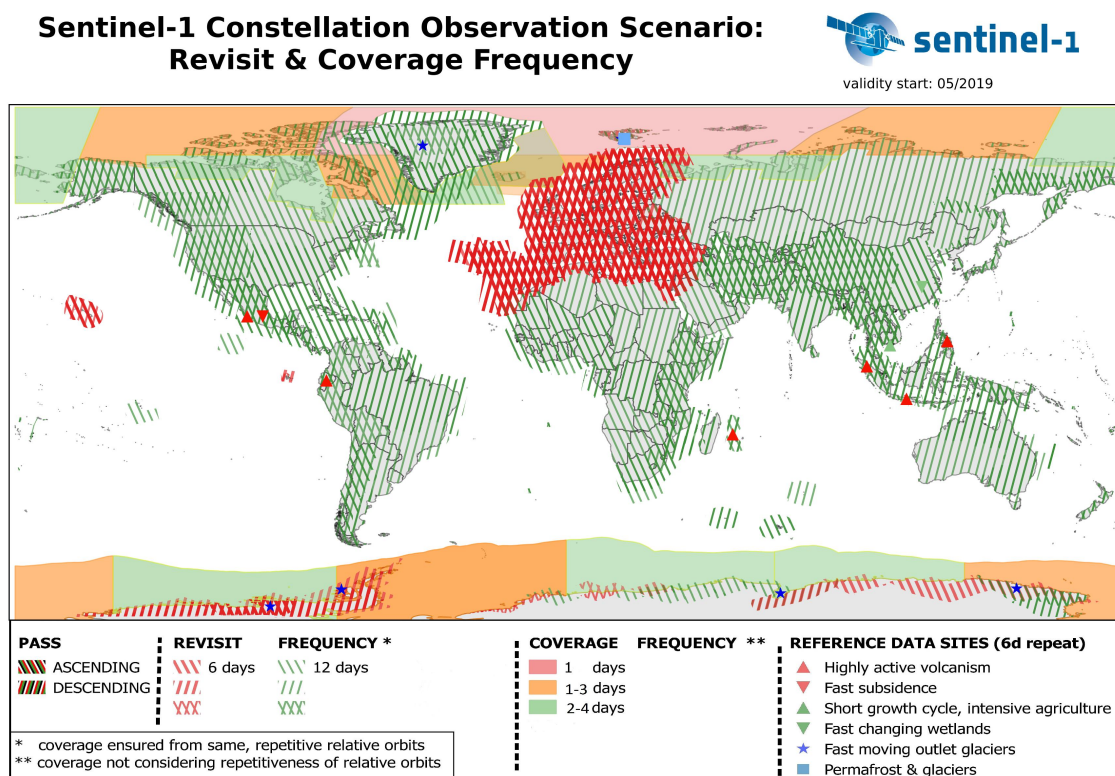
Los productos SLC consisten en datos SAR enfocados georreferenciados utilizando datos de órbita y actitud del satélite, mientras que los GRD consisten en datos SAR enfocados que se han proyectado utilizando un modelo elipsoidal de la Tierra. La información de fase se pierde. El producto resultante tiene píxeles de resolución espacial aproximadamente cuadrados y espaciado de píxeles cuadrados con moteado reducido a costa de una peor resolución espacial.

Los productos GRD pueden estar en una de tres resoluciones: Full Resolution (FR), High Resolution (HR) y Medium Resolution (MR).

- Nivel 2: Son productos oceánicos (OCN) que contienen información sobre velocidad y dirección del viento.

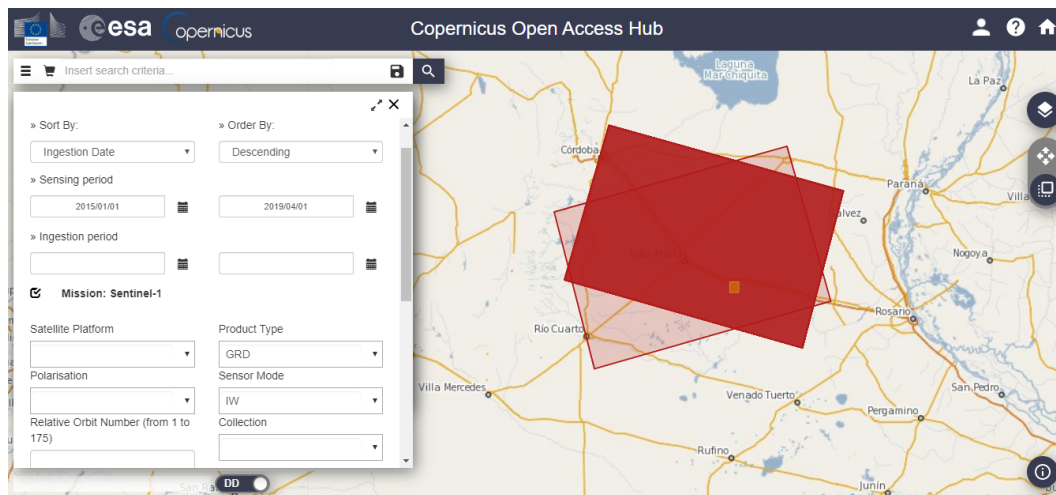
Se debe tener en cuenta también la polarización de los datos, en este caso Sentinel-1 recopila la información terrestre en polarización simple y dual. De esta manera, los productos en modo WV solo estarán disponibles para polarización simple (VV o HH) y para los demás modos, SM, IW y EW, estarán disponibles en polarización dual (VV+VH o HH+HV) o simple.

Los satélites Sentinel-1 tienen cobertura mundial con revisita de 6 días para Europa y de 12 días para el resto del mundo. La figura 4.2 describe de que manera se observa el planeta: frecuencias de cobertura por zona, áreas que tienen pasada ascendente, descendente o ambas, puntos de interés de observación, etc.



**Figura 4.2:** Sentinel-1: Revisita, frecuencia de Cobertura [43]

En el presente trabajo de investigación se utilizaron imágenes SAR Sentinel-1 provistas por el Eurac Research Institute y éstas fueron preprocesadas desde su servidor. Las mismas tienen un tamaño de píxel de 100 por 100 metros aproximadamente, difiriendo del tamaño original del producto IW GRD que se puede encontrar haciendo la descarga desde el sitio oficial de la ESA. Esta diferencia se debe a que este Instituto utiliza esta resolución espacial para generar los productos de humedad de suelo o estudios relacionados con la sequía a escala regional. Estas imágenes también pueden ser descargadas de la plataforma web de la ESA [42] donde el usuario registrado puede filtrar la búsqueda por fecha, zona de estudio, modo de adquisición, plataforma o sensor, tipo de órbita, etc. y ser procesada por el usuario.



**Figura 4.3:** Descarga imágenes Sentinel-1A sobre Bell Ville, Córdoba [42]

Inicialmente, el período utilizado para estudiar el fenómeno de sequía fue la campaña agrícola 2017-2018 sobre el área de estudio espacialmente ubicada sobre las localidades de Bell Ville y Monte Buey. Expertos del INTA afirmaron que en esta ventana espacio-temporal se produjeron severas disminuciones de los rendimientos en cultivos extensivos debido al déficit hídrico [44]. Para comprender de una mejor manera la sequía, se utilizó una ventana temporal aún mayor, comprendida desde 12 de mayo del 2015 al 28 de marzo del 2019. Como resultado de dicha búsqueda en ese período se encontraron 75 imágenes descendentes con una revisita de 12 días. Estas fueron todas las imágenes encontradas desde el lanzamiento de Sentinel-1 hasta marzo 2019 (momento de la descarga).

### 4.1.2. Imágenes ópticas: Sentinel-2

La misión Sentinel-2 es una constelación de dos satélites polares, 2A y 2B, que transportan sensores ópticos multispectrales de alta resolución para el monitoreo de la tierra y de esta manera obtener información de la vegetación, el suelo y el agua. Sentinel-2 también puede proveer información para las emergencias. El satélite Sentinel-2A fue lanzado el 23 de junio del 2015 mientras que el Sentinel-2B lo hizo el 7 de marzo del 2017 [42].

Para este trabajo de investigación se utilizó la misma ventana temporal que para Sentinel-1, es decir desde mayo del 2015 a marzo del 2019, pero no se utilizaron todas las imágenes en este periodo, sino que sólo aquellas que tenían una cercanía de no más de 10 días con respecto a las obtenidas a partir de Sentinel-1. Debido a que los sensores ópticos no pueden atravesar las nubes, sólo se utilizaron 65 imágenes (aproximadamente) para extraer información de los lotes. Las imágenes Sentinel-2 utilizadas fueron obtenidas a partir de la plataforma Google Earth Engine (GEE) donde por medio de un código en Java-Script se puede acceder a la colección de imágenes ópticas proyectadas en superficie, filtradas por fecha y por nubosidad. Una vez filtradas podemos calcular un índice específico, en este caso se lo utilizó el NDVI (Índice de vegetación de diferencia normalizada por sus siglas en inglés) promedio de cada parcela asociada a los sensores de medición de humedad de suelo [45].


En los Anexos B se encuentra el código de GEE del índice NDVI, utilizado en esta tesis para extraer la serie de datos.



### 4.1.3. Datos de Humedad de suelo

Las mediciones de humedad de suelo para la evaluación de la sequía se obtuvieron a partir de la red telemétrica de SAOCOM. Ésta fue creada por la CONAE para la calibración y validación de modelos de humedad de suelo y cuenta con más de 65 sensores en la región de la Pampa Húmeda argentina. Estos sensores de medición se encuentran instalados en diferentes establecimientos públicos o privados que tienen convenio de colaboración con la CONAE como pueden ser los campos del INTA, Servicio Meteorológico Nacional (SMN) o bien lotes privados de productores agropecuarios.

En la zona de estudio (ya descrita en el capítulo anterior) se encuentra el Sitio Núcleo o Core Site que es donde se encuentra la mayor concentración de sensores dentro de la red. Este sitio núcleo cuenta con 26 de la totalidad de sensores, y estos se encuentran indicados con puntos amarillos en la Figura 4.4.



**Figura 4.4:** Core Site de la red telemétrica SAOCOM, Bell Ville- Monte Buey, Córdoba (proyección WGS 84) [37].

La red telemétrica de la misión SAOCOM utiliza sensores de la marca Stevens modelo HydraProbe II para la medición de la Humedad del suelo. Como información complementaria, la sonda HydraProbe mide la temperatura del suelo y la salinidad del suelo. Para la estimación de la humedad de suelo, el fabricante proporciona 4 ecuaciones de calibración dependiendo de la textura de suelo (suelo franco, arenoso, limoso y arcilloso) para la configuración

del sensor. Este sensor presenta la versatilidad de tener la posibilidad de ajustar una ecuación de calibración a partir de un tipo de suelo particular. La sonda HydraProbe es un instrumento basado en impedancia que proporciona mediciones precisas de la humedad del suelo en unidades de fracción de agua por volumen (wfv ó  $m^3 m^{-3}$ ). Es decir, un porcentaje de agua en el suelo que se muestra en forma decimal. Por ejemplo, un contenido de agua de 0.20 wfv significa que una muestra de suelo de un litro contiene 200 ml de agua. La saturación total (todos los espacios de poros del suelo llenos de agua) ocurre típicamente entre 0.3 y 0.45 wfv y depende del tipo de suelo [31].

El sensor HydraProbe II consta de 3 púas equidistantes y una cuarta púa central que se introducen en el suelo a la profundidad deseada. La red telemétrica presenta en todos sus nodos los sensores instalados a 5 cm de profundidad, sin embargo en algunos sitios en particular existe la necesidad para describir la humedad de suelo en el perfil, por lo que coexisten sensores instalados a 10 cm, 50 cm o a 100 cm.



(a) Sitio de medición



(b) Sensor Hydra Probe II



(c) Sensor Hydra Probe II en el perfil de suelo

**Figura 4.5:** Sitio de medición automático de la Red Telemétrica SAOCOM. Las fotos (a) y (c) fueron extraídas de la base de datos del EMIS y la foto (b) de [31]

La Figura 4.5 está dividida en tres partes o subfiguras: La subfigura “a” ejemplifica la instalación de un sitio de muestreo en el medio del campo por lo que la alimentación eléctrica es por medio de un panel solar. En la subfigura “b” se observa un sensor Hydra Probe II con sus

3 púas equidistantes y una cuarta de disposición central. Por último la subfigura “c” muestra un pozo realizado por el EMIS para la instalación de los sensores superficiales (a 5 cm) y en profundidad (10, 50 ó 100 cm).

La CONAE adoptó el uso de estos instrumentos debido a su buen comportamiento en la medición de datos de humedad de suelo, temperatura y salinidad, su calidad de los materiales de fabricación y la robustez de los sensores expuestos a la intemperie [46]. Cabe destacar que este tipo de sensor ya había sido utilizado en la misión SMAP (por sus siglas en inglés: Satélite de medición de humedad de suelo activa y pasiva) de la NASA, que conjuntamente con la CONAE definieron al Core Site como sitio de calibración y validación de dicha misión [47].

### **4.1.4. Datos Climatológicos: Estación meteorológica del IPEA 293 en Bell Ville; y Serie histórica WorldClim**


A modo complementario se utilizaron datos de otras fuentes: El Instituto Provincial de Educación Agrotécnica IPEA 293 – Ing. Agr. Orestes Chiesa Molinari en Bell Ville proporcionó datos de temperatura del aire (exterior al abrigo meteorológico) y precipitaciones tomados a partir de una estación meteorológica (pegasus). Dichos datos fueron tomados por instrumentos Homologados por el Servicio Meteorológico Nacional (SMN) [48].

Del mismo modo se contó con los datos de precipitaciones de las estaciones experimentales de INTA Marcos Juárez (localizado a 50 km de la ciudad de Bell Ville) consultados desde el portal web SIGA de INTA (Sistema de consulta y descarga de datos diarios e información agro-meteorológica histórica a partir de sus Estaciones meteorológicas)[49].


Así mismo se utilizó la plataforma web WorldClim como herramienta para obtener las precipitaciones medias mensuales históricas del sitio de estudio. Desde aquí se obtuvo un raster con datos promedios de precipitaciones desde el año 1970 al 2000 de cada punto con un tamaño de píxel de  $1\text{ km}^2$  [50].

En la Figura 4.6 y 4.7 se muestran las temperaturas medias diarias y las precipitaciones medias mensuales obtenidas de la estación meteorológica del IPEA 293 desde 1 de enero del 2016 al 1 de abril del 2019 respectivamente.


En la Figura 4.8 las precipitaciones medias mensuales de Bell Ville obtenidas de la estación meteorológica del IPEA 293 (en barras azules) comparándolas con las precipitaciones medias históricas obtenidas de la plataforma WorldClim en el periodo antes mencionado. Y por último, en la Figura 4.9 se puede observar la diferencia entre estas dos variables. La misma deja en evidencia una diferencia negativa en tres meses consecutivos: enero, febrero y marzo del año 2018, dejando un déficit de 271.5 mm totales considerando los primeros 3 meses del 2018.




**Figura 4.6:** Temperaturas medias diarias, Bell Ville, Córdoba



**Figura 4.7:** Precipitaciones medias mensuales, Bell Ville, Córdoba



**Figura 4.8:** Precipitaciones medias mensuales vs. precipitaciones medias mensuales históricas, Bell Ville, Córdoba



**Figura 4.9:** Diferencia entre precipitaciones medias mensuales y precipitaciones medias mensuales históricas, Bell Ville, Córdoba



### 4.1.5. Índices de sequía: PDSI y VCI

A continuación se describen dos índices utilizados en esta tesis con el fin de aportar más información de las condiciones locales de los sitios de muestreo dentro del área de estudio, ya sea de la condición hídrica del suelo o de la vegetación, estos son el Índice de Severidad de Sequía de Palmer y el Índice de condición de la vegetación respectivamente.

#### 4.1.5.1. Índice de Palmer PDSI

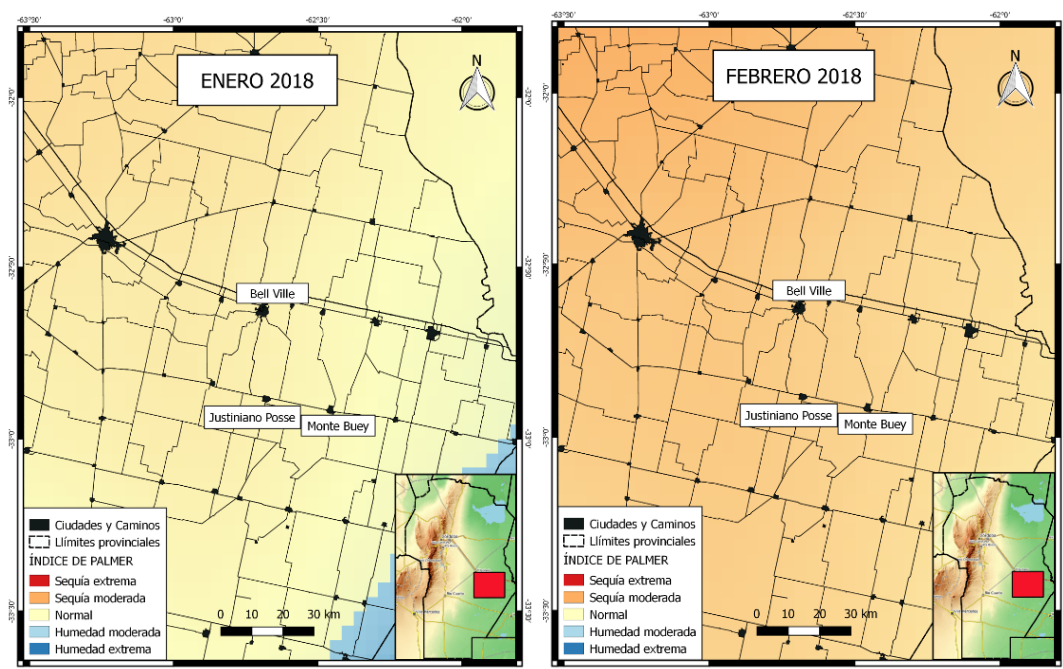
El PDSI o bien el Índice de severidad de sequía de Palmer (por sus siglas en inglés, Palmer drought Severity Index) fue desarrollado para estimar las condiciones de la humedad edáfica e identificar situaciones de exceso, normalidad o deficiencia hídrica. Se basa en el concepto de demanda-suministro de agua o balance hídrico. El procedimiento de cálculo requiere datos de precipitación, evapotranspiración potencial y capacidad de retención de agua del suelo. Las categorías asignadas a los valores van desde sequía extrema a humedad extrema.

En este trabajo de investigación se construyeron los PDSI mensuales en la misma ventana temporal considerada para las imágenes satelitales. Este índice se obtuvo con los datos descargados desde la plataforma de Terra Climate y éstos fueron corridos sobre la plataforma GEE para la extracción de los datos sobre el área de interés [51].

Por ejemplo si tomamos en cuenta los meses en que los datos de la estación meteorológica del IPEA 293 mostró un balance mensual negativo con respecto a las precipitaciones medias históricas podemos ver que en periodo desde enero hasta abril del 2018 fueron críticos para la agricultura de la región en estudio. Por otro lado, tomando los mapas de PDSI de estos meses, podemos comparar y analizar si existe o no una concordancia de la información.

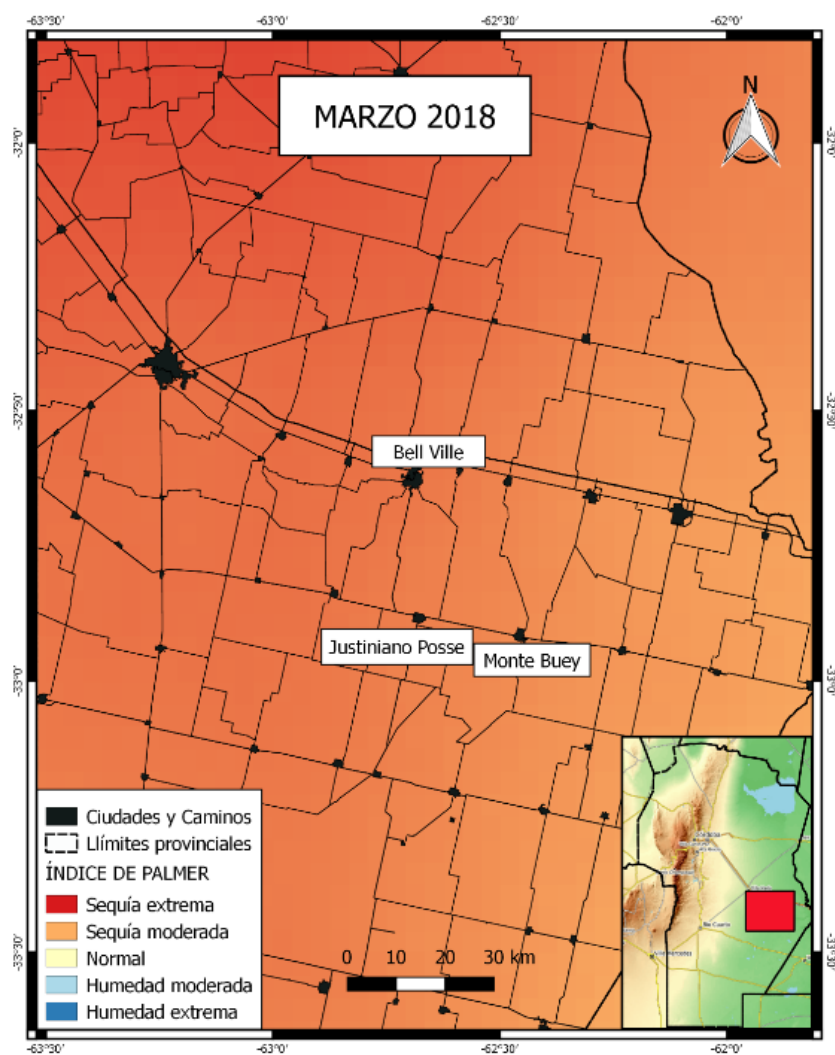
En la Figura 4.10 se muestran tres mapas del área de estudio correspondientes a los PDSI de los meses Enero, Febrero y Marzo del año 2018. La situación hídrica de la región se agrava a medida que se desplaza hacia el noroeste de la provincia. Además se evidencia que a medida que transcurren los meses, el déficit hídrico es cada vez más pronunciado, pasando por sequías leves en enero hasta sequías moderadas y extremas en el mes de marzo en algunos sectores de la provincia.

En los Anexos C se encuentra el código en GEE del índice PDSI, utilizado en esta tesis para extraer la serie de datos.



(a) PDSI Enero 2018

(b) PDSI Febrero 2018



(c) PDSI Marzo 2018

**Figura 4.10:** Índice de severidad de sequía de Palmer

### 4.1.5.2. Índice de la condición de la vegetación VCI

El VCI es un índice posibilita analizar la condición hídrica de la vegetación e identificar las situaciones de estrés hídrico que afectan a la agricultura comparando el Índice mejorado de la vegetación (EVI) actual con el rango de valores observados en el mismo período en años anteriores. El VCI se expresa en porcentaje (%) y da una idea de dónde se encuentra un valor observado con respecto a los valores extremos (mínimo y máximo) en la serie analizada. Los valores más bajos y más altos indican condiciones de estado de vegetación malas y buenas, respectivamente [52].

El VCI se obtuvo a partir de la información proveniente de las imágenes MODIS cada 16 días utilizando también la serie histórica disponible (2001-2019) pero contrastando solamente aquellos resultados que coinciden con la misma ventana temporal considerada para este estudio (2017-2019).

El VCI puede obtenerse a partir de valores de NDVI o bien a partir del EVI. La diferencia radica en que mientras que el NDVI es sensible a la clorofila, el EVI es más sensible a las variaciones estructurales del dosel, incluido el índice de área foliar (LAI), tipo de dosel, fisonomía vegetal y arquitectura del dosel. El uso del EVI tiene mayor utilidad para áreas homogéneas y extensas como es el caso de la zona agrícola donde estamos realizando la investigación.

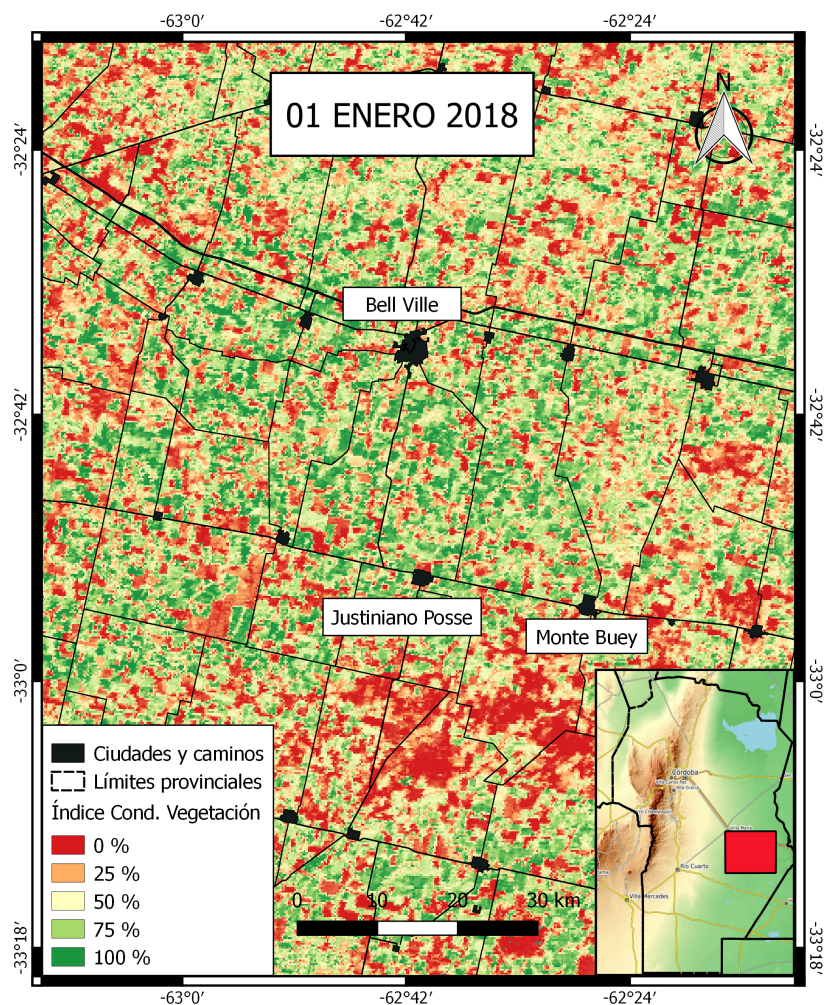
Para calcular el VCI se utilizó la siguiente fórmula:

$$VCI = 100 * (EVI - EVI_{min}) / (EVI_{max} - EVI_{min})$$

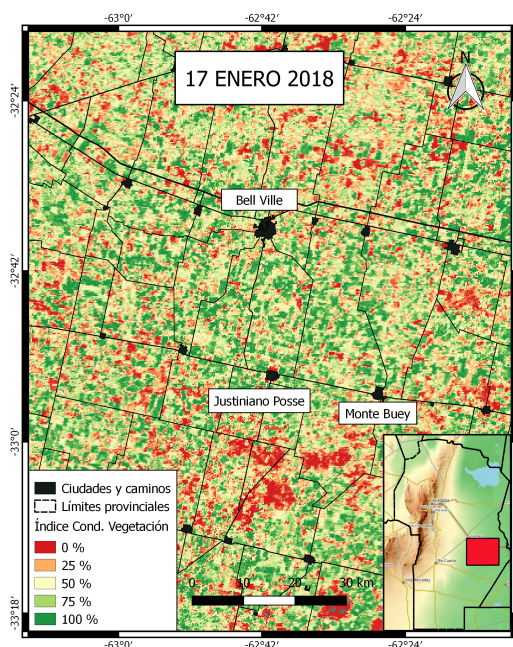
Este índice tiene gran importancia cuando se quiere analizar sequía con imágenes ópticas permitiendo añadir información complementaria al análisis realizado que no puede ser obtenida con un sistema SAR en banda C. Esto se debe a que esta banda en particular no tiene gran penetración en la vegetación.

En las figuras 4.11 y 4.12 se observan los VCI generados con MODIS cada 16 días en los meses de enero, febrero y marzo del 2018 en el área de estudio. Aquí se señala la dinámica de la condición hídrica que expresan los cultivos a partir del EVI, mostrando un aumento de las áreas con gran déficit hídrico. Finalmente, en la imagen del 22 de marzo se observan grandes superficies en donde los cultivos expresan la falta de agua.

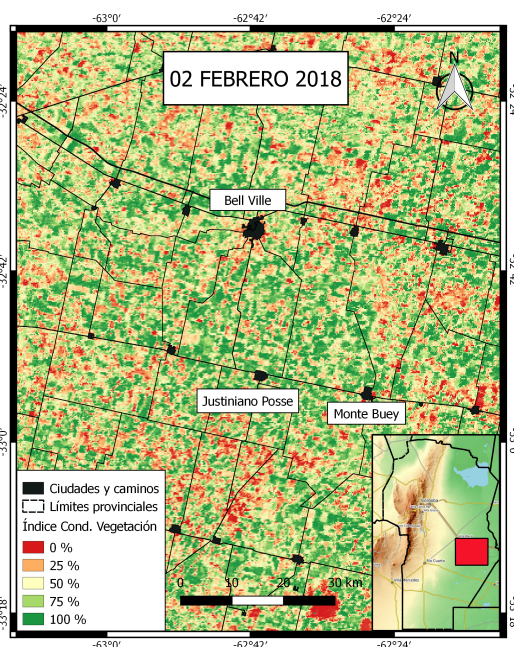
En los Anexos D se encuentra el código en R del índice VCI, utilizado en esta tesis para extraer la serie de datos.



(a) VCI del 1 de Enero 2018



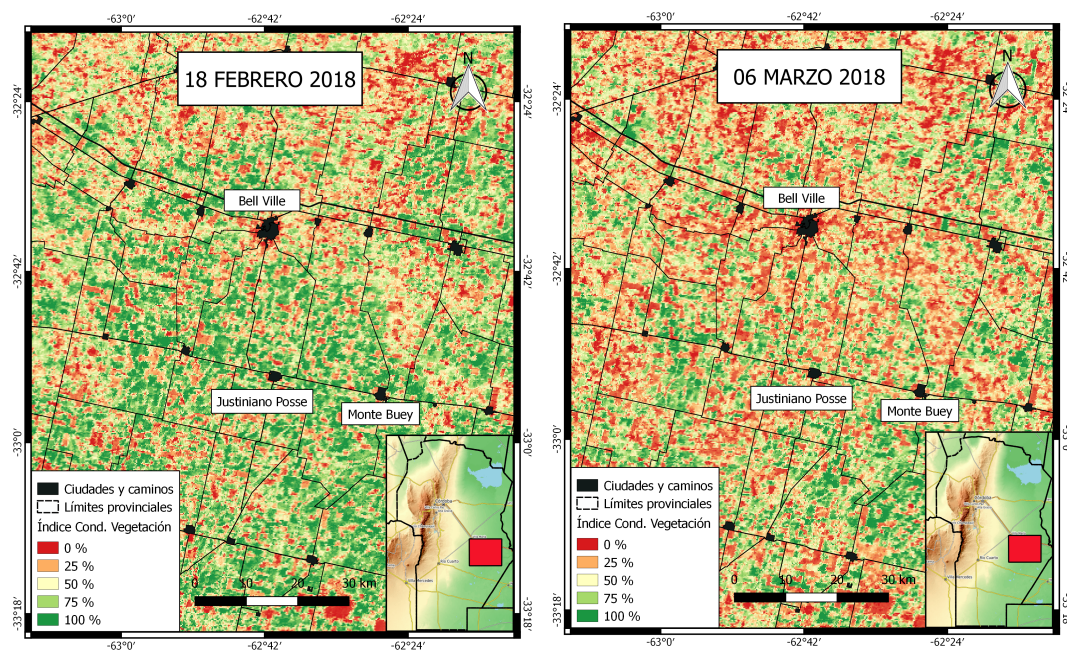
(b) VCI del 17 de Enero



(c) VCI del 2 de Febrero 2018

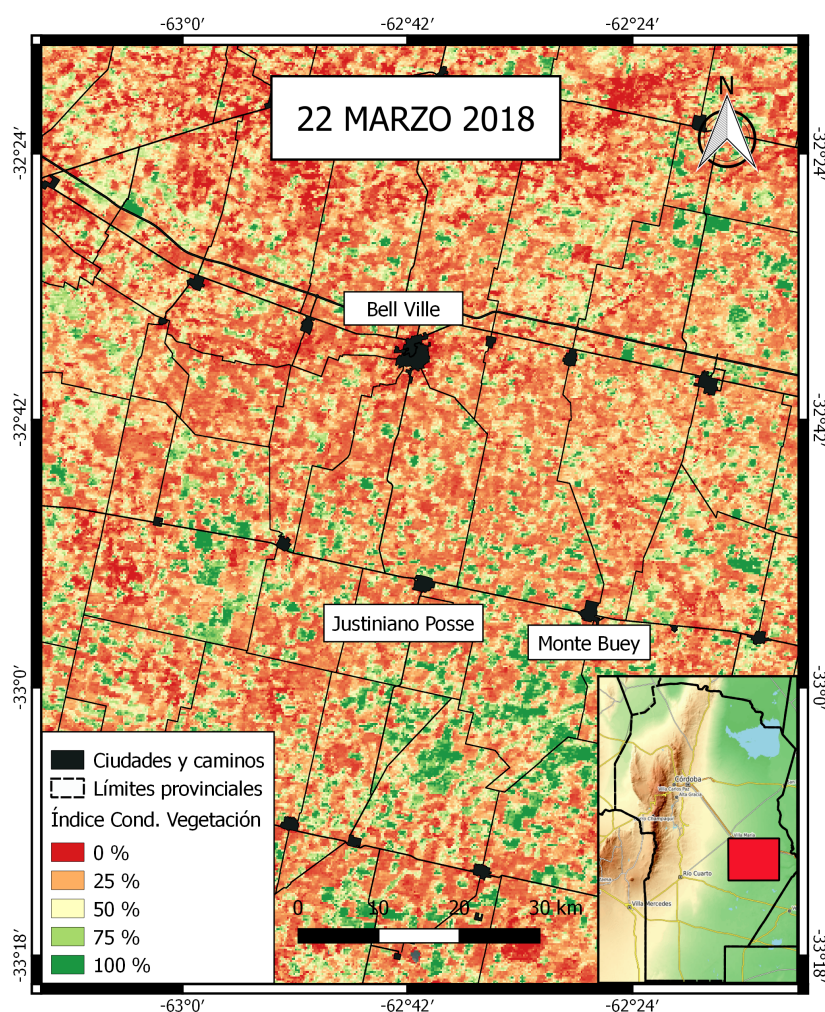
**Figura 4.11:** Índice de condición de la vegetación de Kogan de enero, febrero y marzo del 2018 cada 16 días (primera parte)





(a) VCI del 18 de Enero

(b) VCI del 6 de Marzo de 2018



(c) VCI del 22 de Marzo de 2018

**Figura 4.12:** Índice de condición de la vegetación de Kogan de enero, febrero y marzo del 2018 cada 16 días (segunda parte)

## 4.2. Métodos

### 4.2.1. Preprocesamiento de imágenes Sentinel-1

En esta sección se explicará paso a paso como se procesaron las imágenes satelitales SAR específicamente del satélite Sentinel-1 de la ESA. Esta serie de pasos se realiza para preparar las imágenes para visualizarlas de mejor manera y darle un valor físico a cada píxel de la escena observada.

El conjunto de imágenes utilizadas fue facilitado por el equipo de trabajo del Eurac Research Institute de Bolzano, Italia.

Estas imágenes Sentinel-1 fueron descargadas y procesadas en el software Google Earth Engine (GEE). A partir del producto Nivel-1 Ground Range Detected (GRD), se filtraron por fecha y área de estudio, y por último se remuestrearon a una resolución espacial de 100 metros. El remuestreo a 100 metros de resolución espacial deriva de investigaciones realizadas por EURAC Research Institute, donde probaron el rendimiento del algoritmo SVR con resoluciones de 5, 50, 100 y 500 metros. De esta manera lograron aumentar la resolución espacial a 100 metros, bajar el volumen de datos a procesar y mantener la performance del algoritmo para estimar humedad de suelo [19].

A pesar de ello se procedió a hacer la comprobación y medición del error asociado al remuestreo. Para ello se descargó una imagen de la plataforma Copernicus de la ESA con fecha del 20 de enero del 2018, se preprocesó (con el mismo flujo de trabajo que se describirá más adelante), se extrajeron los datos de las mismas áreas y se realizó una tabla de cálculo donde se compararon los valores de cada parcela en ambas polarizaciones. El resultado muestra un error de 10 % para el promedio de los lotes en VV y de 6 % para VH. En anexos se adjunta la tabla con los datos extraídos (ver figura E.1 en Anexos). De esta manera se pudo disminuir considerablemente el tiempo computacional en el trabajo con imágenes de las características de las Sentinel-1.

Es necesario aclarar que en las imágenes Sentinel-1 los productos Nivel-1 GRD ya vienen con el proceso de multilook realizado y proyectados en tierra con un modelo elipsoidal de la Tierra por lo que no es necesario repetir ese procesamiento [43].

El procesamiento realizado por GEE fue el siguiente:

- Corrección de órbita

Cada imagen viene con un archivo de órbita en sus metadatos pero éstos no son precisos por lo que es necesario aplicarle la corrección de órbita (en el software SNAP, estos valores ya vienen cargados para realizar esta corrección) [24].

- Remoción del ruido de borde

Al generar productos de nivel 1, es necesario corregir la hora de inicio del muestreo para compensar el cambio de curvatura de la Tierra. Al mismo tiempo, la compresión de acimut y rango produce artefactos radiométricos en los bordes de la imagen. El algoritmo de eliminación de ruido de borde, disponible como operador en SNAP, se diseñó para eliminar el ruido de baja intensidad y los datos sobre los bordes de la escena [53]. Este proceso se empezó a realizar a partir del 12 de Enero del 2018 [54].

- **Remoción del ruido térmico**

Con este paso se elimina el ruido aditivo en las sub-franjas para ayudar a reducir las discontinuidades entre ellas. Se utiliza sólo en escenas que contienen modos de adquisición de franjas múltiples [54].

- **Calibración Radiométrica**

El objetivo de la calibración es crear una imagen donde el valor de cada píxel esté relacionado directamente con la retrodispersión de la escena. La calibración radiométrica permite la comparación de imágenes SAR adquiridas con diferentes sensores, o adquiridas con el mismo sensor pero en diferentes momentos, en diferentes modos, o procesadas por diferentes procesadores [22] [55].

- **Corrección de terreno**

El proceso de corrección de terreno, georreferenciación o Terrain Correction (en inglés) se realiza cuando se necesita llevar una imagen SAR a un sistema de coordenadas en un mapa como por ejemplo un sistema de referencias cartográficas. Puede hacerse sin el uso de un modelo digital de elevación (DEM por sus siglas en inglés) o se pueden llevar todos los píxeles al terreno con un DEM preciso [24]. Vale aclarar que mientras mejor sea el DEM mejor va a ser la calidad del trabajo. Se puede contar con algunos que se descargan automáticamente en SNAP o se puede trabajar con un DEM propio y cargarlo al programa.

Por otro lado este procesamiento en la plataforma de GEE no contempla el uso de filtros de Speckle, ni el calculo del ángulo de incidencia local de las imágenes [19].

### 4.2.2. Procesamiento de datos

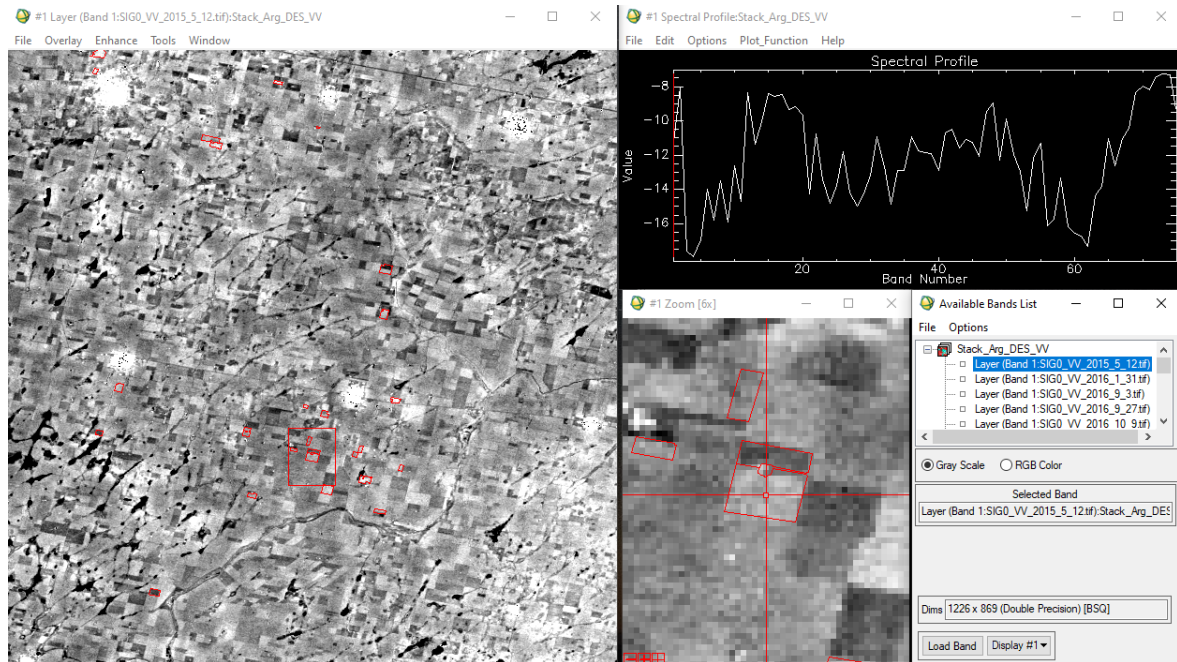
En la zona de estudio, la dinámica y variabilidad de la humedad de suelo, tanto diaria como estacional es captada por los sensores de la red telemétrica de SAOCOM. Conjuntamente con los datos espaciales provenientes de 75 imágenes SAR Sentinel-1, conforman el conjunto de información utilizada para contrastar las estimaciones con respecto a las mediciones de la red. La tarea que se realizará a continuación será extraer estos valores para poder contraponerlos con los provenientes de los sensores de humedad.

Para ello se cargaron las imágenes en el software ENVI, seguidamente se realizó un apilado de las imágenes. Este procedimiento se llama Stack y consiste en agrupar todas las imágenes de una misma área geográfica. Es decir que se obtiene una única imagen que agrupa a las mismas mediante un orden cronológico, en donde la primera es la principal y el resto son las llamadas esclavas. En este trabajo se utilizaron 75 imágenes Sentinel-1 Descendientes de la órbita relativa 39 desde el 12 de mayo del 2015 al 28 de marzo del 2019 [56].

Una vez creado el stack de imágenes, se procedió a añadir los puntos de muestreo. De esta manera podemos ver donde se ubican geográficamente los parcelas del sitio núcleo. A continuación, sobre uno de los lotes de muestreo, se realizó una ventana de 3 por 3 píxeles (Píxel central y su Vecindad de Moore) promediando los 9 valores y se extrajeron todos esos datos de cada una de las imágenes del stack (este procedimiento se llama Z profile en el programa ENVI). El resultado final es un gráfico bidimensional donde se observa la evolución de los datos de retrodispersión con valores de intensidad en dB a lo largo de las imágenes ordenadas cronológicamente. Este procedimiento se repitió para cada uno de los sitios de muestreo y para cada polarización. En el caso de Sentinel-1 se trabajó con las polarizaciones VV y VH.



La Figura 4.13 ilustra el procedimiento realizado en el software ENVI. A la izquierda se muestra en una imagen, el área de estudio superpuesta con el archivo vectorial (en rojo) de los lotes analizados; en el margen superior derecho se observa el gráfico bidimensional de la evolución de la retrodispersión en intensidad (dB) polarización VV dentro de la ventana temporal en estudio; en la imagen central inferior se ve el zoom mostrando el sitio correspondiente al establecimiento n° 8 y con una cruz roja se muestra el píxel central de la ventana 3x3 ya mencionada. Por último y en el margen inferior derecho se observa la ventana de bandas disponibles donde se puede ver el stack en polarización VV conteniendo las bandas con cada una de las fechas ordenadas cronológicamente.



**Figura 4.13:** Salida de ENVI. Z profile sobre el sitio de muestreo n°8 en Monte Buey, Córdoba

Consecuentemente se sistematizó una tabla que ordena los datos provenientes de las distintas plataformas o fuentes de información. Esta tabla es una de las partes más relevantes de esta tesis ya que allí se volcó toda la información recabada que pudieran explicar, de alguna manera, la dinámica y variabilidad de la humedad de suelo. Finalmente este marco de datos o tabla de atributos es la fuente de información con la que se nutre el modelo, por lo que mientras más información contenga la misma, más posibilidades de éxito tendrá el modelo.

Esta tabla se construyó de la siguiente manera para cada sitio de muestreo:

En la primer columna se introdujeron las fechas de las 75 imágenes Sentinel-1 órbita descendente utilizadas comprendiendo una ventana temporal desde el 12 de mayo del 2015 al 28 de marzo del 2019; en la segunda y tercer columna se colocaron los valores de retrodispersión en dB de las imágenes Sentinel-1 en las polarizaciones VH y VV respectivamente; en la cuarta columna se añadieron los valores de NDVI obtenidos a partir de imágenes Sentinel-2. Si bien las fechas de las imágenes Sentinel-2 no son las mismas que las de Sentinel-1, se buscó la máxima proximidad de las mismas. En la quinta y sexta columna se introdujo el índice de sequía de Palmer (PDSI) y el índice de condición de la vegetación (VCI); en la séptima y octava columna se introdujeron los valores climáticos como la temperatura media diaria y las precipitaciones acumuladas de los últimos 6 días a la fecha de la imagen Sentinel-1; por último se agregó el valor de humedad de suelo extraído de los sensores automáticos de la red telemétrica SAOCOM. Esta novena y última columna fue utilizada como verdad de campo donde a partir de las imágenes satelitales y la información complementaria, intentarán pre-



decir la humedad de suelo para lograr identificar anomalías como las sequías.

Este procedimiento se replicó para cada uno de los sitios de muestreo de la red generando una tabla de datos de 1300 filas. A continuación la Tabla 4.1 muestra un fragmento de dicha base de datos.

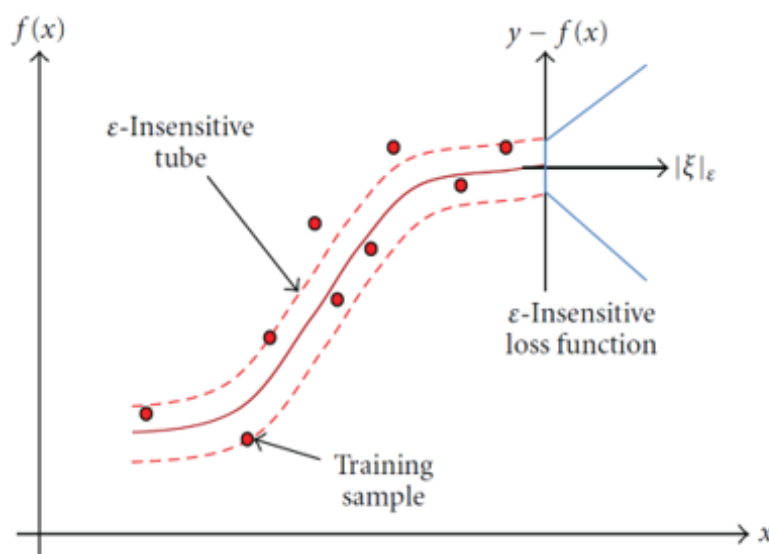
**Tabla 4.1:** Tabla con datos SAR, NDVI, PDSI, VCI, temperatura, precipitaciones y humedad de suelo del lote 66

fecha	VH	VV	NDVI	PDSI	VCI	T° C	PP acum. 6 días	Humedad de suelo
1/8/2018	-18.063	-11.846	0.532	-2.76	29.54	26.8	0.0	0.166
1/20/2018	-16.404	-9.962	0.812	-2.76	100.00	24.0	32.5	0.171
2/1/2018	-16.074	-9.287	0.835	-3.98	96.90	29.1	16.8	0.122
2/13/2018	-16.571	-9.972	0.837	-3.98	98.02	21.5	1.8	0.111
2/25/2018	-16.433	-9.514	0.793	-3.98		23.1	0.0	0.088
3/9/2018	-16.595	-9.982	0.722	-6.01	89.98	26.4	0.3	0.085
3/21/2018	-16.454	-11.006	0.469	-6.01	57.69	17.5	0.3	0.088
4/2/2018	-14.125	-9.351	0.184	-5.76	8.24	19.7	22.0	0.174
4/14/2018	-14.708	-9.619	0.152	-5.76		16.7	2.5	0.277
4/26/2018	-18.949	-11.970	0.116	-5.76	17.81	23.8	18.5	
5/8/2018	-17.120	-10.878	0.27	-4.82	73.99	-0.1	37.5	
6/1/2018	-18.200	-11.204	0.15	-5.15		8.6	2.0	
6/13/2018	-21.100	-11.917	0.044	-5.15	13.01	5.4	0.8	
6/25/2018		-13.465	0.148	-5.15	27.96	8.6	0.0	
7/7/2018	-19.261	-12.109	0.109	-5.21	52.87	-5.0	0.0	0.127
7/19/2018	-17.950	-11.607	0.17	-5.21		8.5	2.0	0.124
7/31/2018		-14.603	0.222	-5.21	4.65	7.0	1.3	0.112
8/12/2018		-14.186	0.277	-5.47	48.24	13.3	1.0	0.103
8/24/2018	-18.416	-11.906	0.295	-5.47	64.57	12.5	1.3	0.089
9/5/2018		-14.063	0.351	-5.04		19.0	1.5	0.083
9/17/2018		-14.527	0.413	-5.04	67.71	18.2	3.8	0.082
9/29/2018		-13.834	0.405	-5.04	43.92	22.1	3.5	0.121
10/11/2018		-15.016	0.408	-5.73		12.7	4.0	0.077
11/4/2018	-20.432	-10.517	0.308	-3.85	19.56	24.2	36.8	0.229
11/16/2018	-18.618	-11.220	0.221	-3.85	30.92	22.4	103.8	0.289
11/28/2018	-15.637	-9.518	0.254	-3.85	80.53	17.2	68.3	0.377
12/10/2018	-17.012	-9.874	0.307			28.3	0.0	
12/22/2018	-16.045	-9.210	0.451		45.66	25.5	31.5	0.371

### 4.2.3. El Modelo: Support Vector Regression (SVR)

Support Vector Machine (SVM) es un algoritmo de aprendizaje supervisado que puede ser aplicado para predicciones del tipo de regresión o de clasificación. En este caso usaremos el primero, el método Support Vector Regression (SVR). Este algoritmo tiene por objetivo encontrar una función  $f(x)$  ya sea una recta, curva o hiperplano que modela la tendencia de los datos con una desviación ( $\varepsilon$ ) aceptable desde los objetivos ( $y$ ) calculados, y al mismo tiempo ser lo más plana posible. Siendo  $\varepsilon$  los rangos permitidos de error que se toleran por encima y por debajo de la línea de tendencia. El área dentro de este rango alrededor de la línea de tendencia debe abarcar la mayor cantidad de puntos posibles, pero como no es posible abarcar todos los puntos dentro de este rango, algunos quedan excluidos. Los puntos que se ubican dentro de esta área no son tenidos en cuenta para el cálculo del error, ya que se consideran que tienen un error aceptable, pero si se tendrán en cuenta para crear la ecuación del modelo aquellos que se ubican por fuera de dicho rango. Estos puntos que caen por fuera del rango serán considerados como error [57] [58].

La línea de tendencia puede ser lineal o no lineal por lo que podemos encontrar una curva como línea de tendencia y por ende el margen por encima y por debajo de ella adoptarán la misma forma.




**Figura 4.14:** Modelo SVR [59]

En la Figura 4.14 se puede observar un gráfico bidimensional en el que se contrasta la variable estimada y la medida o verdad de campo. En este caso de estudio las variables pueden ser la retrodispersión radar y la humedad de suelo medida a campo.

La ventaja de usar este método es que podemos encontrar una relación entre dos o más variables con pocos datos de entrenamientos a diferencia de otros modelos que necesitan miles de datos para el entrenamiento del modelo. Por el contrario el SVR no tiene buen rendimiento cuando los datos son demasiados [59].

La Figura 4.15 muestra como se ejecuta paso a paso el modelo. Como entrada al modelo se ingresa la tabla (explicada en la subsección anterior) con las variables que expliquen a partir de imágenes satelitales, la humedad de suelo o verdad de campo. Estas variables fueron ordenadas en columnas de manera que la última sea la verdad de campo. Además los datos deben ser depurados de manera que no haya celdas vacías, por lo que la fila que contenga celdas vacías debe ser eliminada. A partir de esta tabla, se construye un conjunto de datos que van a ser divididos en datos para entrenamiento y datos para validación. Los datos de entrenamiento y validación deben necesariamente ser diferentes, es por eso que separamos del conjunto de datos: el 80 % para entrenar el modelo y el 20 % para validarlo. Luego a partir de los datos de entrenamiento, se realizan distintos tratamientos y se prueban en cuanto a su comportamiento. Es decir que se realizan pruebas con todos los datos del área de estudio juntos, luego separarlos por sitios espacialmente, o por campañas agrícolas temporalmente, o también se podrían dividir por sitios que tengan los mismos cultivos, etc. Finalmente el modelo arroja dos resultados: el Coeficiente de Determinación ( $R^2$ ), que proporciona una medida sobre la dispersión de las estimaciones alrededor de la línea de regresión lineal (en el caso ideal esta métrica es igual a uno); y el error cuadrático medio (RMSE), que proporciona una idea del error sobre las estimaciones calculadas. La performance del modelo será mayor mientras menor sea el error cuadrático medio (RMSE) y mayor sea el Coeficiente de Determinación ( $R^2$ ) [59].



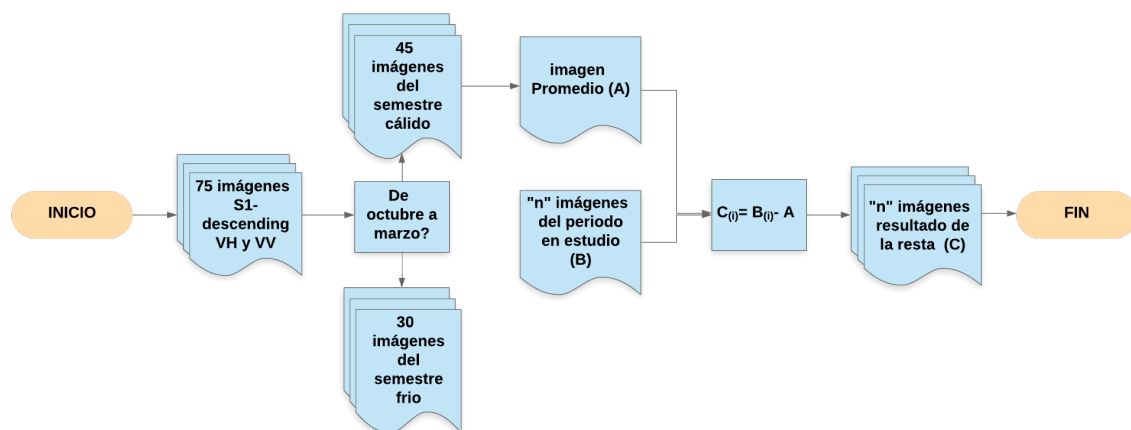
**Figura 4.15:** Diagrama del funcionamiento del Algoritmo SVR.

En los Anexos A se encuentra el código SVR utilizado en lenguaje Python.

#### 4.2.4. Mapa de déficit hídrico

Un mapa de déficit hídrico es una representación del área de estudio georreferenciada donde se detalla en cada píxel información sobre las anomalías de la condición hídrica del lugar. Este mapa sirve para observar las áreas con excesos y déficit hídricos de una fecha en particular, en comparación con la media calculada.

En la 4.16 se muestra el procedimiento detallado de cada uno de los pasos para llegar a este mapa. En primer lugar se tomó el dataset de imágenes Sentinel-1 y se las dividió por semestre: semestre cálido (de octubre a marzo) y semestre frío (de abril a septiembre). Seguidamente se seleccionaron las imágenes del semestre cálido ya que es el periodo que interesa para el estudio que estamos realizando, se apilaron todas las imágenes en un stack y por último se realizó un promedio de todas las imágenes de verano obteniendo un sólo raster como resultado llamándolo Imagen promedio de Verano (A). A continuación se realizó una resta o diferencia entre cada una de las “n” imágenes de período en estudio (B) y la imagen promedio del semestre cálido (A). El resultado son 23 imágenes (C): 8 del año 2017, 7 del año 2018 y 8 del año 2019.



**Figura 4.16:** Diagrama de flujo de la creación del mapa de sequía.

Por medio de un ejemplo se analizará el valor de los resultados posibles en un píxel:

- Si el valor de intensidad (dB) de la retrodispersión de un píxel de una de las “n” imágenes es -24 y el valor promedio de todas las imágenes en el semestre cálido es de -14:

$$x = (-24) - (-14)$$

$$x = (-24) + 14$$

$$x = -10$$

Un resultado negativo en esta diferencia significa que estamos ante la presencia de un píxel con un valor menor al promedio en esa fecha puntual. Esto podría ser un indicador o “proxy” de que el estado hídrico del píxel es menor al que comúnmente tiene el área en esa fecha.

- Pero si en cambio, el valor de intensidad de la retrodispersión de un píxel de una de las “n” imágenes es -10 y el valor promedio de todas las imágenes en el semestre cálido es de -14, el resultado sería el siguiente:

$$x = (-10) - (-14)$$

$$x = (-10) + 14$$

$$x = +4$$

El resultado de esta diferencia arroja un valor positivo. Esto indica que el valor de la imagen “n” es mayor al promedio y podría traducirse en que el estado hídrico del píxel es superior al que comúnmente tiene el área en esa fecha.

El resultado de la diferencia entre cada fecha y el promedio son 45 imágenes (C). De todas estas se analizaron sólo 23 de ellas que son las que pertenecen a los meses de enero, febrero y marzo de 2018 ya que en estos meses se quiere comprobar si hubo o no algún tipo de anomalía hídrica en la zona. A estas 23 imágenes (C) se calculó el histograma en donde se pudo analizar la frecuencia de estos resultados según el rango de valores obtenidos.

Hay que tener en cuenta que a pesar del valor de la diferencia, ese resultado puede estar influenciado por la vegetación (si la hubiera), debido a que la misma tiene un gran impacto en el valor de retrodispersión (influyendo tanto en la forma como en la intensidad de la señal retrodispersada). Sin embargo, esta diferencia puede ser un indicador sencillo de dicha ocurrencia teniendo en cuenta que estamos analizando las anomalías respecto a los valores medios de una serie temporal.

Cada imagen resultado (C) da un valor por píxel que indica si en esa imagen o en ese día la retrodispersión radar está por encima o por debajo del promedio. Mientras mayor sea el número de imágenes con las que se realiza ese promedio, más confiable será ese promedio, pero es necesario aclarar que en este caso sólo se contó con esas 45 imágenes de verano (periodo desde 12 de mayo del 2015 al 28 de marzo del 2019 ) ya que previamente no se registran imágenes disponibles del Satélite Sentinel-1. Es decir que a medida que pasen los años este estudio será más importante realizarlo no sólo porque tendrá mayor número de años para comparar y analizar sino que el promedio generado será más confiable estadísticamente.


#### 5.1. Análisis de Sensibilidad

El SAR emite una señal o eco que ilumina una porción de la tierra. Esta señal interactúa con los elementos de la superficie o el suelo mismo, de manera tal que sólo la porción reflejada en dirección al sensor es lo que el satélite podrá captar y posteriormente transformar en una imagen. Los parámetros de la superficie que influyen en la retrodispersión de la señal son: la estructura, la rugosidad y la constante dieléctrica del objeto blanco. Una correcta interpretación de la señal retrodispersada puede brindar información valiosa que permita inferir sobre la estructuras de los cultivos agrícolas de la zona, la rugosidad del terreno y la humedad del suelo. A pesar de ello se quiere conocer cual es la relación directa que existe entre la señal retrodispersada y la humedad de suelo de un lote agrícola.

Lo primero que se realizó fue un análisis de sensibilidad para corroborar que las variables en estudio tienen relación antes de avanzar con algún examen de mayor complejidad. En consecuencia, se tomó la tabla 4.1 descrita en el capítulo de materiales y métodos y se investigó a cerca de la correlación que existe entre las principales variables bajo estudio.

Para comenzar con el análisis, se correlacionaron las variables de retrodispersión en VH y VV contra la verdad de campo o humedad de suelo, donde los resultados del coeficiente de determinación fueron 0.14 y 0.24 respectivamente. Seguidamente se dividió la ventana temporal en años y se segmentó el período de estudio en campañas agrícolas (por ejemplo la campaña agrícola 2018-19 comprende desde julio del año 2018 a junio del año 2019) siendo la campaña 2018-19 la que presentó mejores resultados alcanzando valores de 0.32 para VH y 0.50 para VV. La Figura 5.1 muestra los resultados.


A su vez se hizo un análisis en cada sitio de muestreo para observar como se comporta la humedad de suelo a partir de la retrodispersión en ambas polarizaciones, siendo los sitios 5, 7, 18, 81, 98 y 99 donde el coeficiente de determinación de las correlaciones mostró mejores resultados. A continuación se verá en detalle algunos sitios en particular a modo de ejemplo.




**Figura 5.1:** Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo en la campaña 2018-19

### ■ Sitio 5

En la Figura 5.2 se puede observar la evolución de la humedad de suelo y la retrodispersión en VH y VV mostrando una correspondencia de las variables en líneas generales. Es decir que en el sitio de muestreo 5 se observó que muchas de las respuestas elevadas del SAR se podrían deber a la interacción con suelos bien provistos de agua. Y en la Figura 5.3 se señala la correlación positiva entre estas variables mostrando un coeficiente de determinación ( $R^2$ ) de 0.548 para el caso de VH y de 0.516 para VV indicando como es la relación entre las variables.




**Figura 5.2:** Evolución de la humedad de suelo medida en campo y retrodispersión en VH y VV de Sentinel-1 en el sitio 5




**Figura 5.3:** Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo medida en campo en el sitio 5

Desde otra perspectiva, se observaron las relaciones que existen entre la retrodispersión y el NDVI ya que, como se dijo en el marco teórico, la señal radar impacta sobre todos los elementos de la superficie y la vegetación es el objeto predominante en este tipo de escenarios

agrícolas. La Figura 5.4 muestra la evolución de los valores la señal retrodispersada del SAR en el sitio 5 distinguiendo pequeñas tendencias cíclicas que correspondientes a la presencia de la vegetación. Esto se puede corroborar superponiendo gráficamente los valores de NDVI de esa parcela. Además en la Figura 5.5 se presentan las correlaciones señalando la relación de dichas estas variables en esa parcela. El  $R^2$  para VH es de 0.246 mientras que para VV es de 0.29.




**Figura 5.4:** Evolución del NDVI del lote y retrodispersión en VH y VV de Sentinel-1 en el sitio 5



**Figura 5.5:** Correlación entre retrodispersión en VH y en VV vs. el NDVI del lote en el sitio 5


También se realizó una prueba filtrando los datos por NDVI (menores a 0.2) para intentar explicar si los suelos poco vegetados tienen mejores correlaciones (entre humedad de suelo y retrodispersión radar). El resultado se muestra en la figura 5.6 donde la correlación entre humedad del suelo y la retrodispersión VH muestra un  $R^2$  de 0.006, mientras que en VV aumenta sólo hasta 0.185. De este análisis podríamos inferir que, en este sitio, cuando hubo poca o nula vegetación no mejoraron las correlaciones entre la humedad de suelo y la retrodispersión radar. Si bien podríamos pensar que un valor bajo de NDVI podría indicarnos escasa o nula vegetación, en realidad nos dice que la actividad fotosintética es baja o nula, por lo que podríamos estar en presencia de restos de cosecha que si intervienen e influyen en los mecanismos de retrodispersión de la señal SAR.




**Figura 5.6:** Correlación entre retrodispersión en VH y en VV vs. la humedad del suelo del lote en el sitio 5 donde los NDVI son menores a 0.2

### ■ Sitio 7

En la figura 5.7 se observan la evolución de la humedad de suelo y la retrodispersión radar a partir de imágenes Sentinel-1 a lo largo de la ventana temporal. Si se correlaciona cada polarización con la humedad de suelo se pueden observar valores en cuanto a coeficiente de determinación de 0.506 y 0.5 de VH y VV respectivamente (ver figura 5.8) mostrando una correspondencia positiva entre las variables.



**Figura 5.7:** Evolución de la humedad de suelo medida en campo y retrodispersión en VH y VV de Sentinel-1 en el sitio 7




**Figura 5.8:** Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo medida en campo en el sitio 7


Sin embargo, también se analizó la evolución del NDVI contra la retrodispersión radar en polarizaciones VV y VH de la parcela (figura 5.9). Como se puede ver en la figura 5.10, las



variables no muestran correlacionarse positivamente, siendo las correlaciones de 0.027 para VH y 0.004 para VV.




**Figura 5.9:** Evolución del NDVI del lote y retrodispersión en VH y VV de Sentinel-1 en el sitio 7




**Figura 5.10:** Correlación entre retrodispersión en VH y en VV vs. NDVI en el sitio 7

### ■ Sitio 3

Otro ejemplo diferente es el sitio 3 que no presenta correlaciones positivas entre la humedad de suelo del lote y la retrodispersión radar. En la figura 5.11 se muestra la evolución de las variables en el tiempo y en la figura 5.12 se muestra las correlaciones individuales con las polarizaciones VH y VV (con valores de 0.102 y 0.16 respectivamente).




**Figura 5.11:** Evolución de la humedad de suelo medida en campo y retrodispersión en VH y VV de Sentinel-1 en el sitio 3




**Figura 5.12:** Correlación entre retrodispersión en VH y en VV vs. la humedad de suelo medida en campo en el sitio 3

De forma análoga a los demás sitios analizados se muestra la evolución del índice NDVI superponiendo la información proveniente del radar en la figura 5.13 y la correlación individual de cada polarización en la figura 5.14 (con valores de 0.101 y 0.299 para VV).




**Figura 5.13:** Evolución del NDVI del lote y retrodispersión en VH y VV de Sentinel-1 en el sitio 3



**Figura 5.14:** Correlación entre retrodispersión en VH y en VV vs. NDVI en el sitio 3

También se puede observar en la Figura 5.15 un diagrama de cajas organizados por sitio de muestreo con todos los datos de humedad de suelo recogidos de la Red Telemétrica SAOCOM. Teniendo en cuenta que son suelos de textura franca, donde el agua rápidamente disponible para las plantas se encuentra entre el 20 y 30 % (vol.) (ver Figura 2.11) y considerando que los puntos de muestreo presentan valores de humedad de suelo entre 15 y 35 % (vol.) en la ventana temporal estudiada, se puede inferir que los suelos, por lo general, se encuentran bien provistos de agua y ésta se encuentra alojada en los mesoporos del suelo (ver Figura 2.10) débilmente retenida por el suelo pero fácilmente disponible para los cultivos.

Del mismo modo, analizando los 20 sitios a lo largo de los 3 años considerados, se registraron escasos valores de humedad de suelo por debajo de 10% (vol). Del total de 20 sitios de medición de humedad de suelo, 9 de ellos presentaron datos faltantes en la ventana temporal donde existió un déficit de precipitaciones según la estación meteorológica del IPEA 293 – Agr. Orestes Chiesa Molinari. La ausencia de telemetría esta asociada a problemas típicos en el mantenimiento de una red, como por ejemplo, daños en panel solar, en el suministro de energía o problemas varios en su funcionamiento, problemas en red de telefonía para envío y recepción de datos, y en menor medida al daño en los sensores entre las dificultades más comunes. Por lo que lamentablemente no se obtuvieron datos en la franja temporal entre enero y abril del 2018 cuando se produjo el evento de sequía de mayor magnitud analizada. Operativamente, estos daños son relevados y son frecuentes en las condiciones de instalación de los mismos (intemperie, exposición a descargas eléctricas, la fauna silvestre presenta afinidad por los cables, la maquinaria agrícola, entre otros). Los protocolos de mantenimiento de la red, definen una planificación anual y un orden de prioridad, vinculado con la posibilidad de atender la mayor cantidad de sitios por campaña, como así también están supeditadas a la disponibilidad de recursos.



**Figura 5.15:** Diagramas de caja de los datos de humedad de suelo medidos por los sensores Hydra Probe II en todos los sitios de muestreo del área de estudio

## 5.2. El Modelo: Support Vector Regression (SVR)

El modelo SVR, descrito en el capítulo de materiales y métodos, fue la herramienta utilizada a la hora de evaluar la performance del modelo para predecir la humedad de suelo en las parcelas de la zona de estudio. Con este método se realizaron numerosas pruebas para dilucidar cuales son las variables que explican mejor la humedad de suelo desde la perspectiva de este modelo. La ventaja de utilizar este modelo es que relaciona todas las variables en un hiperplano multidimensional devolviendo un ajuste multivariable con un  $R^2$  y un RMS que sirve para evaluar la precisión y el error asociado al modelo. Aquella combinación de variables que mayor coeficiente de determinación y menor error serán aquellas que mejor expliquen la humedad de suelo a partir de imágenes SAR.

Como ya se habló anteriormente, humedad de suelo es una variable compleja que depende de numerosos factores como las precipitaciones, la temperatura, la presencia y tipo de vegetación, la pendiente etc., por lo que a partir imágenes SAR e información complementaria relacionada a estas variables fueron correlacionadas con la humedad de suelo de los lotes. Las variables que se pusieron a disposición del algoritmo SVR son: la retrodispersión radar de Sentinel-1 en polarizaciones VH y VV, la temperatura media diaria, las precipitaciones acumuladas los últimos 6 días previos a la adquisición de la imagen S-1, el índice normalizado de vegetación (NDVI), el índice de sequía de Palmer (PDSI) y el índice de condición de la vegetación (VCI). Con toda esta información recopilada a través de distintos medios y plataformas satelitales (Sentinel-1, Sentinel-2 y Modis) se abarcó un gran abanico de información que intentará comprender la humedad de suelo.

A partir de allí se realizaron corridas del algoritmo haciendo distintas pruebas: primero se examinó sitio por sitio, luego se agruparon los sitios por año calendario, luego por campaña agrícola y por último se corrieron todos los datos en conjunto. Estas corridas se realizaron con el 80% de los datos para entrenamiento del modelo y el 20% restante para validación.

Por otro lado, las variables que ingresaron al modelo fueron de menor a mayor, comenzando desde la retrodispersión Sentinel-1 en VH y VV de manera de ir añadiendo de a una variable más en cada prueba hasta probar todas las variables y combinaciones posibles.

Es importante aclarar que el modelo ingiere como entrada, una tabla de datos que debe estar completa en todas las celdas por lo que a medida que se añaden columnas con más variables, esta tabla va perdiendo filas ya que se debe eliminar la fila entera si falta algún valor de una celda.

Los resultados de las corridas de los sitios individuales fueron muy diversos. La baja disponibilidad de datos que un sitio puede presentar en una ventana temporal acotada, dominada por el número de adquisiciones Sentinel-1, hizo que los resultados presentaran un desvío estándar importante en el cálculo del coeficiente de determinación. El tratamiento que mejor resultado observó fue el número 5 nuevamente (como ya se lo había pronosticado en el análisis de sensibilidad), explicando la humedad de suelo a partir de los datos SAR únicamente con un  $R^2$  igual a 0.43 y un RMS 0.04. El sitio 7, evaluando sólo las variables de retrodispersión radar (polarizaciones VH y VV) tuvo resultados de  $R^2$  igual a 0.27 y un RMS 0.04.

Posteriormente al análisis individual por sitio se agruparon los sitios evaluando toda el área de estudio en conjunto, pasando de 50-70 filas de datos a 400-500 filas. En consecuencia, los desvíos estándar de los coeficientes de determinación bajaron considerablemente (como se muestra en la Tabla 5.1). Los resultados de las corridas de toda el área de estudio fueron de menor a mayor a medida que se sumaron paulatinamente las variables NDVI, PDSI, VCI, temperaturas y precipitaciones, llegando a resultados de  $R^2$  de 0.30 y RMS de 0.06 como fue el caso del tratamiento que incluyó VH, VV, NDVI, PDSI, precipitaciones y temperatura.

**Tabla 5.1:** Tratamientos en SVR

Pruebas	Sitios	media R2	desvio R2	media RMS	desvio RMS
VV y VH	5	0.4295	0.3145	0.0411	0.0109
VV y VH	7	0.2777	0.2959	0.0406	0.0064
VV y VH	todos	0.0235	0.0429	0.0758	0.0044
VH-VV-NDVI	todos	0.0254	0.0686	0.0765	0.0042
VH-VV-NDVI- PDSI	todos	0.1591	0.0605	0.0708	0.0038
VH - VV - NDVI - PP - T°C-PDSI	todos	0.3025	0.0663	0.0644	0.004
VV - NDVI - PP - T°C-PDSI	todos	0.2947	0.0661	0.0651	0.0039
Fecha-VH - VV - NDVI - PP - T°C- PDSI	todos	0.2802	0.0697	0.0657	0.0042
VV - NDVI - PP - T°C-PDSI- VCI	todos	0.2243	0.137	0.0681	0.0066
VH - VV - NDVI - PP - T°C-PDSI- VCI	todos	0.2312	0.1276	0.0686	0.0082
Fecha-VH - VV - NDVI - PP - T°C-PDSI- VCI	todos	0.2257	0.141	0.0682	0.0074

Se puede decir entonces que hay tratamientos que tuvieron resultados aceptables pero con una alta variabilidad de resultados, ya que si se repite el mismo tratamiento, el algoritmo a la hora de seleccionar el porcentaje para entrenamiento y testeo, lo hace aleatoriamente. Esto significa que si se tienen pocos datos puede haber una gran variabilidad en los resultados, siendo un indicio de que el modelo arroja mejores resultados, o mejor dicho, resultados más confiables a medida que se aumentan los datos a evaluar. Por esta razón, para estabilizar los resultados generales se decidió iterar el procesamiento cien veces y se calculó tanto la media como el desvío estándar del coeficiente de determinación y del error ( $R^2$  y RMS respectivamente). A medida que se hicieron pruebas con más sitios o con toda la zona de estudio como un conjunto, el desvío de los resultados bajó considerablemente.

Por último, se probó realizando una corrida del algoritmo filtrando sólo las celdas que tuvieran asociadas a un valor de NDVI menor a 0.2. A diferencia del análisis preliminar, no se correlacionaron los datos del sitio 5 solamente, sino que con el algoritmo SVR se lo hizo para todos los sitios en conjunto. Considerando que, como se dijo anteriormente, un valor bajo de NDVI no significa que el suelo este desnudo, sino que existe poca o nula actividad fotosintética, se decidió hacer la prueba para comprobar si existía alguna correlación. Las variables involucradas en este caso fueron: retrodispersión VV, VH y humedad de suelo. El resultado fue un  $R^2$  de 0.1 (coincidiendo con lo obtenido en el análisis preliminar) por lo que se infiere que la presencia y tipo de rastrojo de los cultivos tienen, de alguna manera, influencia en la retrodispersión de la señal radar tanto por su estructura como por su contenido de humedad.

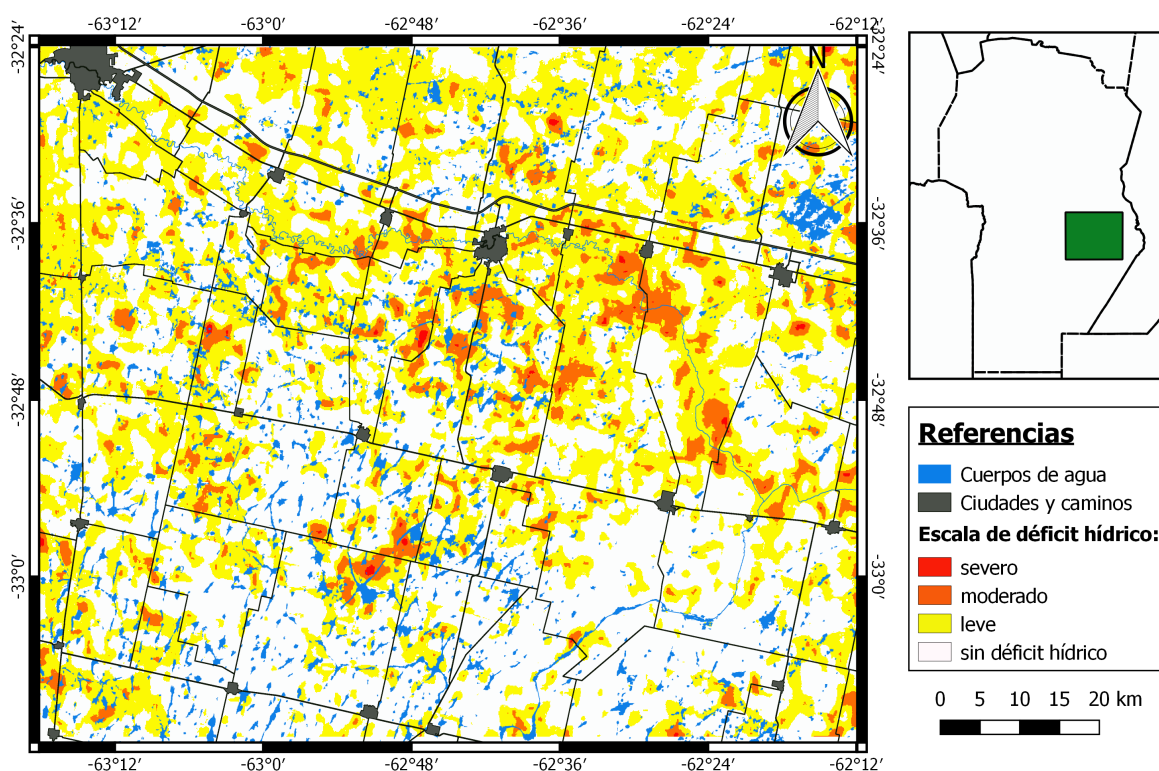
Los resultados obtenidos con el algoritmo SVR, fueron análogos a los obtenidos por otros investigadores [60] [61]. En términos de correspondencia podemos decir que la información contenida dentro de la longitud de onda (banda C), como así también las polarizaciones analizadas (VV,VH) no fueron las más prometedoras para el estudio de la humedad del suelo, como si lo sería, en principio, la banda L y la polarización HH [60], por lo que se descarta la posibilidad de mapear la humedad de suelo con los datos predichos y la obtención de la función que ajusta a dichos parámetros

### 5.3. Mapa de déficit hídrico

El resultado de este análisis, esta representado por 23 imágenes (álgebra de bandas) y sus respectivos histogramas de frecuencia. A modo de ejemplo rescataamos la imagen del 21 de marzo del 2018 y su histograma. Esta imagen fue elegida como modelo ya que fue la que registró mayores anomalías en dB con respecto valor medio de la serie. A posteriori y de manera comparativa, visualizaremos el resto de las imágenes, para comprender la dinámica que se quiere representar.

La Figura 5.16 muestra la zona de estudio donde los ejidos urbanos y las rutas o caminos principales están coloreados de verde, los cursos de agua están pintados de celeste y por último se puede ver que el mapa esta categorizado en amarillo, naranja y rojo. La escala representa las zonas en donde el cálculo entre el valor medio de la serie y el valor de la fecha analizada se contrastan y nos dan una idea de las anomalías en dB.

Esta anomalía nos permiten asociar de manera práctica, variaciones en dB con las épocas en donde las regiones espaciales analizadas cursaban diferentes sequías, posiblemente por un menor aporte en retrodispersión por efecto de la constante dieléctrica disminuida en un suelo seco, como así también por los cambios estructurales en la vegetación agrícola en una situación de stress hídrico.



**Figura 5.16:** Mapa de déficit hídrico del 21 de marzo del 2018 (proyección WGS 84)


El histograma asociado a cada imagen muestra cual es la distribución de los valores en dB de los píxeles de la imagen. El rango de valores obtenidos va de -6 a +6 dB. Un valor positivo significa que el valor del píxel es mayor que el valor medio de la serie, mientras que un valor negativo significa que el valor actual del píxel es menor que el valor promedio de la serie. Ahora bien, los valores positivos podrían estar asociados a suelos bien provistos de agua, plantas en buen estado de salud, turgentes y vigorosas. Pero por el lado contrario los valores negativos se los podría asociar con suelos pobres con malas condiciones hídricas,

que no tienen agua fácilmente disponible para las plantas, plantas que adoptan mecanismos de defensa como la inversión de hojas, cierre estomático, y a medida que la situación hídrica empeora la planta se deshidrata y muere.

Además, analizando el histograma completo, y no por el valor puntual de cada píxel, se puede inferir sobre la situación hídrica de la imagen. Si el histograma presenta una campana recostada sobre el lado derecho donde se encuentran los valores positivos, indicaría que la imagen tiene una gran mayoría de los píxeles con buen estado hídrico en sus cubiertas vegetales. Por el contrario si la campana se encuentra recostada sobre la izquierda, la mayor cantidad de píxeles se encontrarían con algún tipo de estrés en esa fecha particular. Una situación intermedia donde la campana se encuentra centrada en el valor cero puede indicar dos cosas: que los valores de los píxeles son similares al promedio realizado entre las 23 imágenes o bien que se encuentran en equilibrio las situaciones de estrés y de exceso de humedad dentro del área en esa fecha.

La Figura 5.17 se observa un histograma típico en una situación de anomalía negativa para nuestro mapa de déficit hídrico, correspondiente a la fecha 21 de marzo del 2018. A partir de ésta, se interpreta que la escena podría presentar grandes áreas de suelos pobremente provistos de agua, estrés hídrico en sus cultivos y algunas zonas podrían verse comprometidas gravemente debido a la deshidratación irreversible de sus cultivos implantados.

La banda C por sus características no posibilita una gran penetración en el dosel de la vegetación, lo que implica que es una longitud de onda adecuada para clasificación de cultivos y no muy adecuada para determinación de humedad de suelo. De igual modo las polarizaciones disponibles en Sentinel-1 son VH y VV mientras que la polarización más adecuada para un estudio de humedad de suelo es HH. [60].



**Figura 5.17:** Histograma déficit hídrico del 21 de marzo de 2018 (ENVI versión 5.5.1)

A continuación, se ordenaron cronológicamente en grillas los histogramas y las imágenes analizando cuales fueron las fechas donde hubo déficit hídrico, cual fue el comportamiento interanual, si ese déficit fue en una imagen puntual o tuvo permanencia en el tiempo provocando una sequía y cuales fueron las zonas dentro del área donde esta sequía permaneció en el tiempo. Las Figuras 5.18 y 5.19 se encuentran ordenadas por año en filas y cada 10 días desde enero a marzo inclusive en las columnas. Las imágenes están espaciadas temporalmente cada 12 días (tiempo de revisita del satélite o resolución temporal) por lo que al estar ordenadas cada 10 días se pueden encontrar celdas que no contengan imágenes.

El año 2017 nos muestra algunas zonas coloreadas a mediados y fines de enero y también a mediados de marzo pero observando los histogramas correspondientes a esas fechas se puede ver que las campanas están centradas o próximas a cero, lo que demuestra que fue un año neutro donde no se presentaron ni excesos ni deficiencias hídricas importantes. Estos supuestos pueden ser corroborados con los datos de precipitaciones descriptos anteriormente en el capítulo de materiales y métodos (Figura 4.8 y 4.9).

El año 2018, es el año en donde se registraron muy pocas precipitaciones en los meses de verano ocasionando grandes pérdidas en los cultivos estivales. Esta falta de lluvias en la zona las podemos ver a lo largo de todo el verano en la Figura 5.19. Luego, la situación parece agravarse a fines de marzo donde la sequía cobró mayor intensidad y se generalizó en toda la escena coloreando la imagen en casi toda su totalidad. Estas imágenes pueden ser contrastadas con los mapas creados en base a índices de sequía y de condición de la vegetación que fueron expuestos en el capítulo de materiales y métodos (ver 4.10, 4.11 y 4.12). De este manera se ha abordado la problemática desde diferentes perspectivas: retrodispersión radar, índice de sequía de Palmer, índice de condición de la vegetación y datos meteorológicos, validando de alguna manera los mapas de déficit hídricos presentados (aunque no tengan una validación espacial in situ de la condición de los lotes y los cultivos). Asimismo, algunos periódicos nacionales registraron en sus páginas a esta sequía como un evento catastrófico [62], [63], [64], [65]. También se encontraron informes técnicos de las principales instituciones nacionales registrando este fenómeno [44] [66].

Por último en el año 2019 que previamente se mostraba en los registros como un año húmedo, en el análisis de las imágenes se puede corroborar lo esperado ya que pocos sectores aparecen coloreados de amarillo. Estas zonas coloreadas son de corta duración por lo que no se repiten en la imagen siguiente. También se puede ver esta tendencia observando los histogramas donde son frecuentes las campanas inclinada hacia los valores positivos indicando que predominaron las áreas húmedas por sobre las secas.

Entonces, habiendo explorado la temática desde distintos sensores, resulta interesante la comparación entre la información generada a partir de imágenes ópticas y SAR con el objetivo de comprobar si existen similitudes. Para ello se tomaron los mapas de VCI generados en el capítulo anterior y se los ordenaron en una grilla cronológica junto con sus respectivos histogramas, de la misma manera que se realizó para los déficits hídricos. Esta grilla se muestra en la figura 5.20 (los histogramas corresponden a la misma área para que la comparación sea adecuada). También se extrajeron las estadísticas de estos datos y se muestran en la figura 5.21.

Analizando la grilla fecha a fecha, se observa como a partir del 1 de enero del 2018 los valores del índice disminuyen asociándose a condiciones de vegetación malas, a su vez en su histograma correspondiente, la frecuencia de los datos se muestra de manera homogénea como ocurre dicho agravamiento a lo largo del mismo. Esto puede notarse en la figura de las estadísticas por fecha donde la media y el desvío son de 47.5 y 30.5 respectivamente, describiendo el histograma. En las 3 fechas siguientes se puede observar como las zonas rojas al sur de Justiniano Posse y Monte Buey disminuyen mientras que se observa un agravamiento de la sequía al norte de la ruta 9 llegando al 18 de febrero. Los histogramas de estas 3 fechas muestran medias por encima de 50 % y los valores del desvío se mantiene aproximadamente constante (con valores entre 28.3 y 29.6). A partir del 6 de marzo el mapa de VCI muestra como la condición de la vegetación se agrava hasta el 22 de marzo donde se observa el peor escenario. Aquí el histograma refleja el problema dibujando una campana con una media de 36.1 y un desvío de 25.8. Valores entre 30 y 40 % indican sequía leve por lo que la media de la zona se encuentra en esa situación, aunque el pico del histograma es del 15 % señalando



que muchos píxeles se encuentran en situaciones de sequía moderada y severa ya que esos valores se acercan al mínimo histórico del índice EVI.


Esta grilla de VCI muestra gran similitud con lo observado en los mapas de déficit hídrico. Si bien las fechas son distintas, difieren en pocos días ya que Sentinel-1 tiene una revisita de 12 días y Modis de 16 días permitiendo la comparación de la información proveniente de ambos sensores. Ambas grillas tienen coincidencias en la distribución de la situación en la que se encuentra la vegetación a lo largo del trimestre, mostrando la peor escena en la segunda quincena de marzo.

### 5.3.1. Superficie del déficit hídrico


A partir de los mapas generados se puede calcular el área que ocupa cada categoría de déficit hídrico en el área de estudio en cada fecha en particular. Es por ello que se tomó el mapa del 21 de marzo del 2018 que representa la imagen con mayor anomalías en dB y se procedió a calcular la superficie en cada condición hídrica como se muestra en la tabla 5.2. Estos se calcularon con el software QGis multiplicando el número de píxeles que se encuentran en cada categoría por la superficie del píxel. Este simple procedimiento nos muestra numéricamente que aproximadamente el 60 % del área de la zona de estudio se encontró bajo déficit hídrico en esa fecha.

**Tabla 5.2:** Superficie por condición hídrica a la fecha del 21 de marzo del 2018

Condición Hídrica	Superficie (miles ha)	Porcentaje (%)
déficit hídrico leve	496.0	46.6
déficit hídrico moderado	128.3	12.0
déficit hídrico severo	5.2	0.5
sin déficit hídrico	435.7	40.9
total	1065.2	100.0



**Figura 5.18:** Histogramas de los mapas de déficit hídricos ordenados cronológicamente, Bell Ville, Córdoba



**Figura 5.19:** Imágenes de los mapas de déficit hídricos ordenados cronológicamente, Bell Ville, Córdoba

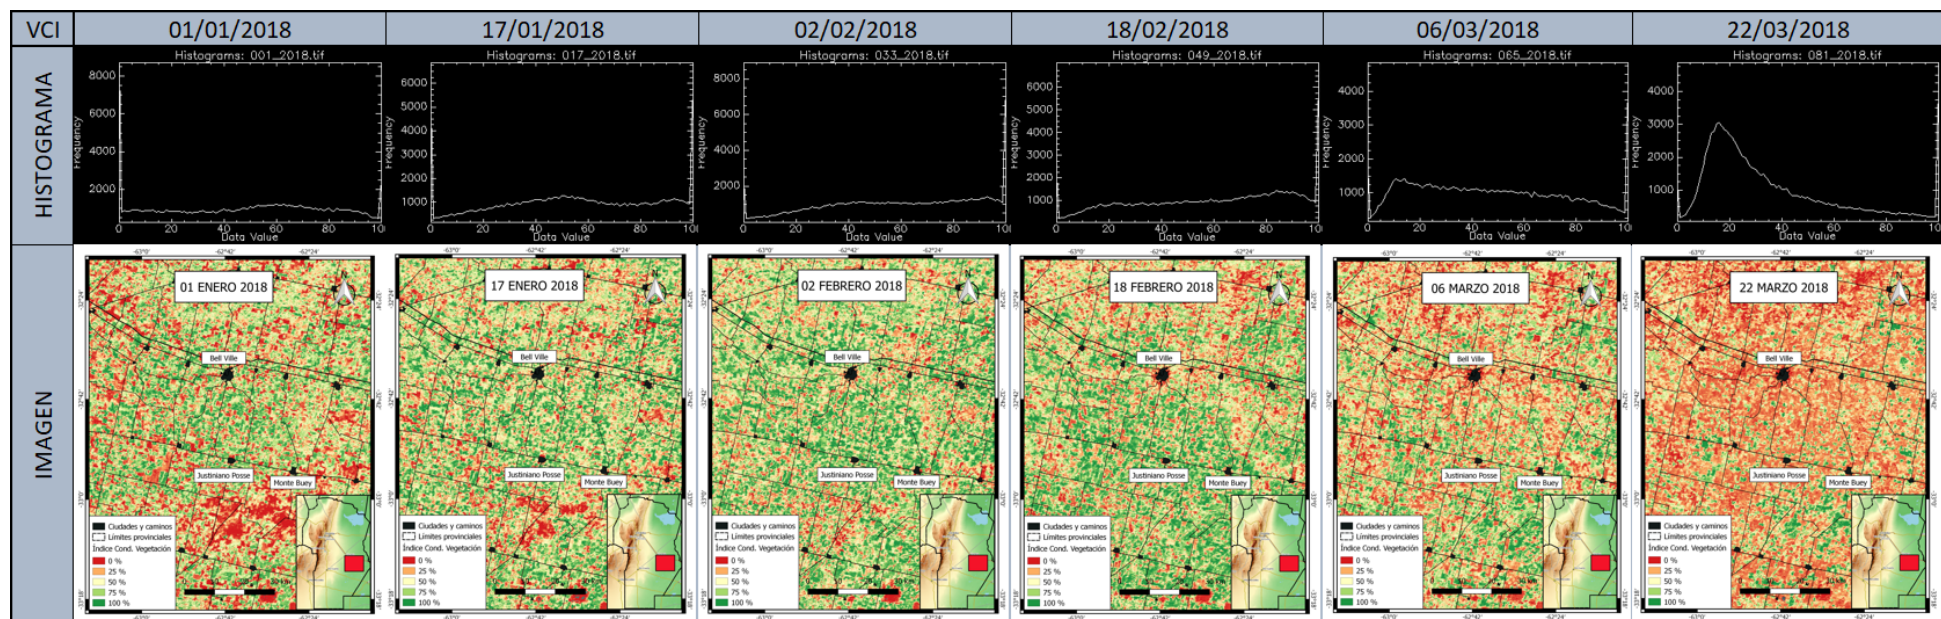


Figura 5.20: Histogramas e imágenes de los VCI ordenados cronológicamente

FECHA	MIN	MAX	MEDIA	DESVÍO
01/01/2018	0	100	47,4	30,5
17/01/2018	0	100	55,1	29,6
02/02/2018	0	100	60,9	28,3
18/02/2018	0	100	59,1	29,0
06/03/2018	0	100	47,7	28,6
22/03/2018	0	100	36,1	25,8

Figura 5.21: Estadísticas extraídas de los histogramas de VCI

---

### Conclusiones y propuestas de investigación

---

En esta tesis se propuso como objetivo la detección y mapeo de áreas con sequía a partir del uso de imágenes SAR de la misión Sentinel-1. En primer lugar se evaluó el desempeño del algoritmo SVR en la obtención de la humedad del suelo principalmente a partir del datos SAR. Esta evaluación incluyó la exploración de distintas variables relacionadas al contenido de agua en el suelo como son: la temperatura y precipitaciones (extraídas de una estación meteorológica local), datos de NDVI (extraídos del sensores ópticos como es Sentinel-2), índices como PDSI y VCI (este último fue extraído a partir de imágenes MODIS).

Los resultados no superaron valores de 0.5 a pesar de haber utilizado variables complementarias que aporten información para explicar la humedad del suelo y la influencia de la vegetación en ésta. Por lo expuesto anteriormente se puede concluir que no es adecuado la utilización del algoritmo SVR para recuperar la humedad de suelo a partir de sensores banda C con las polarizaciones VH y VV sobre lotes agrícolas en el área estudiada.

Esto se debe a que la interacción de la señal con el objetivo depende de diversos factores del sensor (longitud de onda, polarización y ángulo de incidencia) y de la superficie (constante dieléctrica, rugosidad y vegetación):

- longitud de onda: La banda C no es la más adecuada para estudios de humedad de suelo debido a que la onda electromagnética tiene interacción con la vegetación pero la penetración a través de la misma es de apenas de pocos centímetros, sin llegar al suelo en la mayoría de los casos. Un factor importante a considerar es que en la zona donde se sitúa la investigación contiene cultivos agrícolas (maíz y soja principalmente) que presentan alturas y densidades de plantas considerables. Es decir que en condiciones de alto contenido de biomasa, la recuperación de la humedad del suelo con la banda C se encuentra disminuida por la interferencia de la estructura vegetal.
- Polarización: Las polarizaciones utilizadas (VH y VV) no son las más adecuadas para estudios de humedad de suelo, siendo HH la que mejor correlación presenta en este tipo de investigaciones.
- Ángulo de incidencia: Se analizó el ángulo de incidencia de la zona de estudio y el mismo se encuentra entre los valores mínimos y máximos de 31.5 y 35.9 mientras,



en paralelo la diferencia angular que existe en un producto IW de S1 varía entre los 30 y 45.8 respectivamente (estos números coinciden con los observados en el manual de usuario de Sentinel-1 [43]). En esta tesis no se realizó ningún análisis en cuanto al ángulo de incidencia debido a que el área de estudio no fue considerada como una superficie significativamente afectada por la variación propia de ángulo de incidencia en una imagen Topsar como las S1 IW analizadas.

- **Rugosidad:** Esta variable no fue tomada en cuenta en el análisis realizado debido a que la zona de estudio cultiva, desde hace 30 años, con sistema de siembra directa, es decir sin remoción del suelo. Esto significa que no existen variaciones importantes en la rugosidad del suelo, salvo excepciones para solucionar algún problema de compactación o planchado del suelo. Por otro lado, la señal del SAR interacciona con el conjunto suelo-planta y debido a la longitud de onda del sensor no le es posible penetrar hasta el suelo cuando el cultivo se encuentra implantado. Pero es posible que la falta de buenos resultados en SVR puede deberse a este factor.
- **Vegetación:** Si bien se conoce que tipo de vegetación predomina en la zona, no se contó con datos precisos de cuales son los cultivos presentes en cada lote. Además hubiera sido valioso contar con información complementaria de fonología y fonometría para comprender la interacción de la banda C en cada cultivo.

En cuanto a los mapas de déficit hídrico realizados se puede concluir que es posible identificar cuales son las posibles áreas bajo régimen de sequía, cual es su intensidad (dependiendo de cuanto se aleje el valor del píxel del valor promedio de la serie), cual es su duración (conociendo la persistencia de ese píxel en esa condición hídrica en el tiempo) y en la visualización de los mapas de déficit hídrico de la vegetación podemos conocer como se mueve cada categoría de intensidad de sequía en el tiempo. Además es factible calcular la superficie bajo estrés en cada fecha de manera general o discriminando por intensidad del estrés (déficit hídrico leve, moderado o severo). La confiabilidad de los resultados podría incrementarse a medida que aumente la duración de la serie.

Este análisis realizado con imágenes SAR fue corroborado con el VCI realizado a partir de un sensor óptico (MODIS). Si bien ambos son sensores que aportan información distinta, se pudo extraer conclusiones similares en cuanto al déficit hídrico de la zona de estudio.

Es importante comprender que ocurre dentro de un cultivo cuando el agua comienza a escasear y ese déficit se incrementa cada vez más. Por ejemplo, si se considera un suelo que contiene poca humedad, y esta humedad es retenida fuertemente por las partículas del suelo de manera que es muy difícil para la planta extraerla, la planta comenzará por activar mecanismos para sobreponerse a la falta de agua. Estos mecanismos son: disminuye la expansión foliar, aumenta del crecimiento radicular, se produce el cierre estomático (estructuras responsables del intercambio gaseoso), las hojas cambian de orientación, etc. Si la planta no puede compensar la falta de agua con alguno de estos mecanismos se deshidrata. Esta deshidratación puede ser extrema e irreversible haciendo que la planta o el cultivo entero mueran. Los cambios de estructura que suponen estos eventos fisiológicos adversos en los cultivos podrían ser capturados por la señal SAR, logrando así una identificación de estas anomalías, la cuantificación de la superficie que ocupa, su intensidad y su duración.

A partir del aprendizaje generado luego de la realización de esta tesis se están evaluando imágenes SAOCOM, correlacionando la retrodispersión SAR con la humedad de suelo, siguiendo con esta línea de trabajo pero aplicando los conocimientos adquiridos en el proceso.

Este nuevo análisis tiene algunas variantes respecto al trabajo realizado en la tesis como ser:

- Utilización de imágenes SAOCOM: el mismo tiene un sensor de Banda L, que por sus características electromagnéticas (longitud de onda de 23 cm), es el adecuado para realizar estudios de humedad de suelo, debido principalmente a la capacidad de penetración en la vegetación.
- Polarización: SAOCOM es un satélite full-polarimétrico (tiene todas las polarizaciones: VV, VH, HV y HH) permitiendo la utilización de la polarización HH, que es la más apropiada para realizar estudios de humedad de suelo.
- Datos de validación: se realizaron cambios en las campañas de recolección de datos para validación para continuar con este análisis y poder comprender como es la interacción de la señal SAR en banda L con cada uno de los cultivos presentes en la zona. Para ello, no solo se realizaron las mediciones de humedad de suelo, sino que se tomó información complementaria como tipo de cultivo, fenología y fenometría.

### 6.1. Propuestas de investigación

La versatilidad de los algoritmos no escapa al analizado por lo que en términos de posibles evaluaciones futuras, es factible proponer la utilización de SVR con imágenes SAOCOM utilizando sus 4 polarizaciones y contando con el aporte de los datos recabados por el EMIS de la CONAE utilizando datos como humedad de suelo e información complementaria de los lotes agrícolas donde se realizan estas mediciones (presencia y tipo de cultivos, fenología y fenometría).

También resultaría importante considerar la influencia de la rugosidad del conjunto suelo-cultivo.

Además se propone incorporar el análisis de la influencia del ángulo de incidencia para poder extrapolar este estudio a superficies mayores.

Asimismo, sería interesante evaluar la interacción de la señal SAR en otras coberturas como sorgo, maní, arroz, etc.

Por último sería valioso poder realizar mapas de déficit hídricos con una serie temporal mayor que contemple años secos, lluviosos e intermedios (más de 5-7 años). De esta manera, el promedio de la serie tendría un valor más confiable y representativo con la realidad.

---

## Referencias Bibliográficas

---

- [1] Canada Centre for Remote Sensing- Globesar program, “Material educativo para teledetección mediante radares,” *Canada Centre for Remote Sensing*, 2000.
- [2] E. Chuvieco Salinero, *Teledetección ambiental: la observación de la Tierra desde el espacio*. Ariel,, 2006.
- [3] S. A. C. Cravero, C. L. Bianchi, H. J. Elena, and A. R. Bianchi, “Clima de argentina: Mapas digitales mensuales de precipitación y precipitación menos evapotranspiración potencial. adenda del atlas climático digital de la república argentina,” *Instituto Nacional de Tecnología Agropecuaria*, 2017.
- [4] FAO- Organización de las Naciones Unidas para la alimentación y la agricultura, “Portal de suelos de la fao.” <http://www.fao.org/soils-portal/soil-survey/propiedades-del-suelo/propiedades-fisicas/es/>. (visitado el 12/11/2020).
- [5] C. Perez and A. L. Muñoz, *Teledetección: nociones y aplicaciones*. carlos perez, 2006.
- [6] T. Lillesand, R. W. Kiefer, and J. Chipman, *Remote sensing and image interpretation*. John Wiley & Sons, 2015.
- [7] A. C. Ravelo, R. Zanvettor, and P. Boletta, “Atlas de sequía de la república argentina. crean- centro de relevamiento y evaluación de recursos agrícolas y naturales,” *Versión digital en www. crean. unc. edu. ar*, p. 18, September 2014.
- [8] A. Ravelo, R. Sanz-Ramos, and J. Douriet-Cárdenas, “Detección, evaluación y pronóstico de las sequías en la región del organismo de cuenca pacífico norte, méxico,” *Agriscientia*, vol. 31, no. 1, pp. 11–24, 2014.
- [9] Ó. M. Valiente, “Sequía: definiciones, tipologías y métodos de cuantificación,” *Investigaciones geográficas*, no. 26, pp. 59–80, 2001.
- [10] D. B. Lobell, K. G. Cassman, and C. B. Field, “Crop yield gaps: their importance, magnitudes, and causes,” *Annual review of environment and resources*, vol. 34, pp. 179–204, 2009.
- [11] J. Nuñez Cobo and K. Verbist, *Atlas de sequías de América Latina y el Caribe*. UNESCO Publishing, 2018.

- [12] A. Ravelo, A. Planchuelo, R. Zanvettor, and P. Boletta, “Sistema de monitoreo y evaluación de las sequías en argentina,” *Agrometeoros*, vol. 24, no. 01, pp. 113–120, 2016.
- [13] S. Beguería, B. Latorre, F. Reig, and S. Vicente-Serrano, “Spei global drought monitor,” *Recuperado de <http://spei.csic.es/map/maps.html#months>*, vol. 1, 2017.
- [14] A. Ravelo, A. Planchuelo, R. Zanvettor, and P. Boletta, *Atlas de sequías de América Latina y el Caribe*. UNESCO, 2004.
- [15] A. A. Belal, H. R. El-Ramady, E. S. Mohamed, and A. M. Saleh, “Drought risk assessment using remote sensing and GIS techniques,” *Arabian Journal of Geosciences*, 2014.
- [16] J. A. C. Rodríguez, H. Vergara, and D. X. Vanegas, “Evaluación del nivel de mejora en el monitoreo de sequías a escala regional en colombia, a partir de indicadores ecohidrológicos basados en teledetección,” *Revista de Tecnología*, vol. 15, no. 2, pp. 15–42, 2016.
- [17] N. Sánchez, Á. González-Zamora, M. Piles, and J. Martínez-Fernández, “A new Soil Moisture Agricultural Drought Index (SMADI) integrating MODIS and SMOS products: A case of study over the Iberian Peninsula,” *Remote Sensing*, 2016.
- [18] M. González Elizondo, E. Jurado Ybarra, S. González Elizondo, Ó. A. Aguirre Calderón, J. Jiménez Pérez, and J. d. J. Nívar Cháidez, “Cambio climático mundial: origen y consecuencias,” *Ciencia uanl*, vol. 6, no. 3, 2003.
- [19] F. Greifeneder, C. Notarnicola, and W. Wagner, “Towards a data driven approach for the global estimation of surface soil moisture based on sentinel-1,” *Living Planet Symposium- Milan*, 2019.
- [20] G. Cuzzo, F. Greifeneder, A. Padovano, R. Solorza, G. Bertoldi, and C. Notarnicola, “Virtual constellation of xc and l band sar images to assess soil and vegetation water content in agricultural areas,” in *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, pp. 7310–7313, IEEE, 2019.
- [21] J. Tullis, J. Cothren, D. Lanter, X. Shi, W. Limp, R. Linck, and T. Alsumaiti, “In remotely sensed data characterization, classification, and accuracies,” 2016.
- [22] E. Podest, “Conceptos Básicos del Radar de Apertura Sintética (Synthetic Aperture Radar o SAR) ,” *Programa de entrenamiento en sensado remoto aplicado de NASA*, 2017.
- [23] I. G. Pascual, “Clasificación de áreas sembradas y determinación del momento de cosecha en Caña de azúcar y Pastizales mediante imágenes ópticas y SAR,” tech. rep., Instituto Gulich, 2018.
- [24] C. Notarnicola, “Introduction to sar systems: acquisitions, geometry, focalization and distorsions, part 2- celfi-2018,” *celfi*, 2018.
- [25] A. Moreira, P. Prats-iraola, M. Younis, G. Krieger, I. Hajnsek, and K. P. Papathanassiou, “SAR-Tutorial-March-2013,” *ieee Geoscience and remote sensing magazine*, no. march, 2013.
- [26] C. Notarnicola, “Introduction to sar systems: acquisitions, geometry, focalization and distorsions, part 1- celfi-2018,” *CELF*, 2018.



- [27] R. Solorza, “Estimación de la humedad superficial del suelo mediante el uso combinado de modelos electromagnéticos y el enfoque bayesiano . Estudio exploratorio en imágenes SARAT .,” *Instituto Gulich*, 2013.
- [28] F. Shaxson and R. Barber, *Optimizacion De La Humedad Del Suelo Para La Produccion Vegetal-el Significado De La Porosidad Del Suelo*, vol. 79. Food & Agriculture Org., 2008.
- [29] A. J. López, “Manual de edafología,” *Departamento de Cristalografía, Mineralogía y Química. Agrícola de la Universidad de Sevilla*, 2005.
- [30] G. Angella, C. Frías, and R. Salgado, “Conceptos básicos de las relaciones agua-sueloplanta,” *INTA. Buenos Aires-Argentina*, 2016.
- [31] Stevens® Water Monitoring System, Inc., *The Hydra Probe ® Soil Sensor*, 2008.
- [32] N. C. Brady, R. R. Weil, and R. R. Weil, *The nature and properties of soils*, vol. 13. Prentice Hall Upper Saddle River, NJ, 2008.
- [33] A. Beccari and H. Videla, “Brecha de rendimiento de maíz temprano y tardío en la región sudeste de córdoba,” tech. rep., Ediciones INTA; Estación Experimental Agropecuaria Marcos Juárez, 2018.
- [34] V. J. Gudelj, P. S. Vallone, C. M. Galarza, H. J. Anselmi, H. R. Donadio, A. G. Salafia, H. Videla, and M. B. Conde, “Evaluación de la fertilización en maíz con nitrógeno, fósforo, azufre y zinc,” tech. rep., Ediciones INTA; Estación Experimental Agropecuaria Marcos Juárez, 2018.
- [35] J. Andriani, I.-E. Oliveros, and S. Fe, “Lo que hay que saber del consumo de agua de los cultivos,” *Para mejorar la producción. INTA EEA Oliveros*, no. 50, p. 100, 2016.
- [36] MAGyP- Estimaciones Agrícolas. <http://datosestimaciones.magyp.gob.ar/>.
- [37] QGIS Development Team, *QGIS Geographic Information System*. Open Source Geospatial Foundation, 2009.
- [38] Agencia Córdoba Ambiente, “Recursos Naturales de la Provincia de Córdoba - LOS SUELOS-Nivel de Reconocimiento 1:500.000,” *INTA*, 2006.
- [39] C. A. Ghida Daza and C. Sánchez, “Zonas agroeconómicas homogéneas córdoba,” *Cartilla Digital INTA*, no. 3, 2009.
- [40] A. L. Cabrera, “Regiones fitogeográficas argentinas,” *Editorial Acme*, 1976.
- [41] S. O. Dequino and A. Ferreiro, “Uso del suelo y caracterización productiva al 2019. departamentos general san martín, río segundo, tercero arriba y unión. cuenca lechera central de la provincia de córdoba,” tech. rep., AER Villa María, Córdoba, 2019.
- [42] ESA, European Epace Agency, “Copernicus.” <https://scihub.copernicus.eu/>, 2019.
- [43] ESA, European Space Agency, “Handbook Sentinel-1,” *ESA- European Space Agency*, pp. 1–81, 2013.

- [44] S. Muñoz and L. Segura, “Informe de sequía en el territorio este de Córdoba campaña 2017-2018,” *INTA*, 2018.
- [45] N. Gorelick, M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore, “Google earth engine: Planetary-scale geospatial analysis for everyone,” *Remote Sensing of Environment*, 2017.
- [46] Stevens-HydraProbeII. <https://www.stevenswater.com/products/hydraprobe/>, 2019.
- [47] M. Thibeault, J. M. Cáceres, D. Dadamia, A. G. Soldano, M. U. Quirno, J. M. Guerrieri, R. Edrosa, M. Palomeque, L. Romaldi, J. Pucheta, *et al.*, “Spatial and temporal analysis of the monte buey saocom and smap core site,” in *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 969–971, IEEE, 2015.
- [48] Instituto Provincial de Educación Agrotécnica (I.P.E.A.) 293 , Agr. Orestes Chiesa Molinari. <http://www.ena.edu.ar/wp/about/servicio-meteorologico/>.
- [49] SIGA, Sistema de Información y Gestión Agrometeorológica. <http://sig2.inta.gov.ar/>, 2017. Consulta de información de las estaciones meteorológicas argentinas.
- [50] WorldClim- Global Climate Data. <http://http://worldclim.org/>.
- [51] “Terra climate.” [https://developers.google.com/earth-engine/datasets/catalog/IDAHO\\_EPSCOR\\_TERRACLIMATE#description](https://developers.google.com/earth-engine/datasets/catalog/IDAHO_EPSCOR_TERRACLIMATE#description). (Accessed on 07/20/2020).
- [52] F. N. Kogan, “Application of vegetation index and brightness temperature for drought detection,” *Advances in space research*, vol. 15, no. 11, pp. 91–100, 1995.
- [53] F. Filipponi, “Sentinel-1 grd preprocessing workflow,” in *Multidisciplinary Digital Publishing Institute Proceedings*, vol. 18, p. 11, 2019.
- [54] G. E. E.-U. Guide. <https://developers.google.com/earth-engine/guides/sentinel1/>, 2019.
- [55] N. Morandeira and C. Notarnicola, “Data Access and SAR preprocessing,” *Escuela de Primavera en Teledetección, El SAR como herramienta de monitoreo del medio ambiente y la producción. Instituto Gulich- Universidad Nacional de Córdoba- CONAE*, 2018.
- [56] Exelis VIS, *Environment for Visualizing Images (ENVI)*. Exelis Visual Information Solutions, Boulder, Colorado, 2017.
- [57] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Statistics and computing*, vol. 14, no. 3, pp. 199–222, 2004.
- [58] L. Pasolli, C. Notarnicola, and L. Bruzzone, “Estimating soil moisture with the support vector regression technique,” *IEEE Geoscience and remote sensing letters*, vol. 8, no. 6, pp. 1080–1084, 2011.

- [59] L. Pasolli, C. Notarnicola, L. Bruzzone, G. Bertoldi, S. Della Chiesa, V. Hell, G. Niedrist, U. Tappeiner, M. Zebisch, F. Del Frate, *et al.*, “Estimation of soil moisture in an alpine catchment with radarsat2 images,” *Applied and Environmental Soil Science*, 2011.
- [60] C. Notarnicola, “Soil moisture detection and retrieval approaches,” *Maestría en Aplicaciones de Información Satelital 2016- Asignatura :Radar- Instituto Gulich*, 2016.
- [61] P. Pampaloni, E. Santi, S. Paloscia, S. Pettinato, and P. Poggi, “Radar remote sensing of soil moisture, envisnow project,” tech. rep., SMC algorithms. Technical report, IFAC-CNR, 2004.
- [62] Diario La Nación- 26 de diciembre de 2018, “La sequía en la argentina, entre los 10 fenómenos climáticos más destructivos del año.” [https://www.lanacion.com.ar/sociedad/cambio-climatico-sequia-argentina-diez-fenomenos\\_meteorologicos-nid2205680](https://www.lanacion.com.ar/sociedad/cambio-climatico-sequia-argentina-diez-fenomenos_meteorologicos-nid2205680). (visitado el 02/11/2020).
- [63] Diario Perfil- 21 de febrero 2018, “Fotos: La sequía más importante de los últimos 70 años en Argentina.” [https://www.perfil.com/noticias/sociedad/fotos-de-la-sequia-mas-importante-de-los-ultimos-70-anos\\_en-argentina.phtml](https://www.perfil.com/noticias/sociedad/fotos-de-la-sequia-mas-importante-de-los-ultimos-70-anos_en-argentina.phtml). (visitado el 12/12/2019).
- [64] Diario La Nación- 19 de abril 2018, “Tras la mayor sequía en 50 años, cuáles son las provincias que están en emergencia.” [https://www.lanacion.com.ar/economia/campo/tras-la-mayor-sequia-en-50-anos-cuales-son-las-provincias\\_que-estan-en-emergencia-nid2126686](https://www.lanacion.com.ar/economia/campo/tras-la-mayor-sequia-en-50-anos-cuales-son-las-provincias_que-estan-en-emergencia-nid2126686). (visitado el 12/12/2019).
- [65] Diario Clarin- 19 de abril 2018, “Primer cálculo es oficial: las pérdidas por sequía alcanzan al 23% de la soja y al 18% del maíz.” [https://www.clarin.com/rural/oficial-perdidas-sequia-alcanzan-23-soja-18-maiz\\_0\\_HyWT3o83M.html](https://www.clarin.com/rural/oficial-perdidas-sequia-alcanzan-23-soja-18-maiz_0_HyWT3o83M.html). (visitado el 12/12/2019).
- [66] J. L. Stella *et al.*, “Informe especial de la sequía 2017-2018 en la región pampeana,” *Servicio Meteorológico Nacional. Gerencia de Investigación, Desarrollo y ...*, 2018.

---

## Código en Python del algoritmo SVR

---

```
import pandas as pd
import numpy as np
from sklearn.svm import SVR
from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score
from math import sqrt
import matplotlib.pyplot as plt
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import GridSearchCV

count=0
r_cuad=[]
error=[]

#Cargar el dataset o tabla generada
#Los datos deberan ser ordenados de la siguiente manera:
#las primeras "n" columnas seran ocupadas por las variables
#a testear.
#La ultima columna sera ocupada por la humedad de suelo o
#verdad de campo.
#si la celda no contiene datos, debera eliminar la fila
#el archivo debe estar en formato csv.

dataset=pd.read_csv('C:/Escritorio/tablaSVR.csv',sep=',')

while count<100:
    train , test = np.split(dataset.sample(frac=1),
        [int(.8*len(dataset)), int(.81*len(dataset))])
```

```
X = train.iloc[:,0:8].values
y = train.iloc[:,9].values
y = y.reshape(158,1)
y_test = y_test.reshape(38,1)

scaler = StandardScaler()
X_train = scaler.fit_transform(X)
X_test = scaler.transform(X_test)

svr = GridSearchCV(SVR(kernel='rbf', cache_size=8000),
scoring = 'r2', cv=3,
param_grid={"C": np.logspace(-2, 2, 15),
"gamma": np.logspace(-2, 1, 15),
"epsilon": np.logspace(-2, 2, 15)},
n_jobs=-1)

##### AJUSTE #####
svr.fit(scaler.transform(X_train), y)
#####

y_pred_svr = svr.predict(scaler.transform(X_test))

#graficos
plt.plot(y_test, y_pred_svr, 'bo')
plt.title("SMC_measure_vs._predicted")
plt.xlabel("SMC(measured)")
plt.ylabel("SMC(predicted)")
plt.xlim(0.0,0.45)
plt.ylim(0.0,0.45)

#coeficiente de determinacion R2 y RMS
R=r2_score(y_test, y_pred_svr)
r_cuad.append(R)
rms = sqrt(mean_squared_error(y_test, y_pred_svr))
error.append(rms)
count=count+1

#Resultados impresos en consola
print('fin')
print("R2_medio_es:", (np.mean(r_cuad)))
print("R2_desv_std_es:",(np.std(r_cuad)))
print("RMS_medio_es:", (np.mean(error)))
print("RMS_desv_std_es:", (np.std(error)))
}
```

---

### Código en GEE de NDVI

---

```
// Crear un coleccion de imagenes S-2 para el periodo 2016-19
var S2 = ee.ImageCollection('COPERNICUS/S2_SR')
    .filterDate('2019-01-01', '2020-03-31')
    .filterMetadata('CLOUD_COVERAGE_ASSESSMENT',
        'less_than', 20)
    .filterBounds(area);

// Enmascarar las nubes
var maskcloud1 = function(image) {
var QA60 = image.select(['QA60']);
return image.updateMask(QA60.lt(1));

// Calcular y agregar una banda con el NDVI
var addNDVI = function(image) {
return image.addBands(image.normalizedDifference
(['B8', 'B4']));

// Agregar la banda NDVI creada a la coleccion
var S2 = S2.map(addNDVI);

// Extraer la banda NDVI y crear una composicion con
// la mediana
// del NDVI
var NDVI = S2.select(['nd']);
var S2med = S2.median();
var NDVImed = NDVI.median();
//renombrar la variable

// Crear un grafico con la serie de tiempo.
var plotNDVI = ui.Chart.image.seriesByRegion
```

```
(S2, area, ee.Reducer.mean(), 'nd',
10, 'system:time_start', 'system:NDVI')
    .setChartType('LineChart').setOptions({
        title: 'NDVI_lote',
        hAxis: {title: 'Fecha'},
        vAxis: {title: 'NDVI'}},));

// Imprimir el grafico
print(plotNDVI);

// Parametros de visualizacion
var visParams={bands: ['B4','B3','B2'],max:3048,gamma:1};
var visParams_false={bands: ['B8','B4','B3'], max:3048, gamma:1};
var visParams_ndvi={min:0, max:1, palette:'FFFFFF,CE7E45,
DF923D,F1B555,FCD163,99B718,74A901,66A000,529400,3E8601,
207401,056201,004C00,023B01,012E01,011D01,011301'};

// Crear un buffer de 1000 metros alrededor del lote
var bufferBy = function(size) {
    return function(feature) {
        return feature.buffer(size)}};
var roi = area.map(bufferBy(1000));

// Visualizar el NDVI en el mapa
Map.addLayer(NDVImed.clip(roi),visParams_ndvi,'S2_NDVI');
Map.addLayer(S2med.clip(roi),visParams,'S2_Real_Color');
Map.addLayer(area,{color: 'FF0000'},"lote");
Map.centerObject(area,13);

var titulo = ui.Label({
    value:"NDVI",
    style:{position: "top-center",
    fontWeight:"bold",
    fontSize:"15px"}});
Map.add(titulo);
```

---

### Código en GEE de PDSI

---

```
var dataset = ee.ImageCollection('IDAHO_EPSCOR/
TERRACLIMATE')
    .filter(ee.Filter.date('2017-12-01', '2017-12-31'))
    .filterBounds(zona_1).mean();
var pdsi = dataset.select('pdsi');
var pdsiVis = {
  min: -4000,
  max: 4000,
  palette: [
    '1a3678', '2955bc', '5699ff', '8dbae9', 'acd1ff',
    'caebff', 'e5f9ff', 'fdffb4', 'ffe6a2', 'ffc969',
    'ffa12d', 'ff7c1f', 'ca531a', 'ff0000', 'ab0000'
  ],
};
Map.setCenter(-63.51, -33.65, 5);
Map.addLayer(pdsi, pdsiVis, 'pdsi');

// Export a cloud-optimized GeoTIFF.
Export.image.toDrive({
  image: pdsi,
  description: 'PDSI',
  scale: 100,
  region: zona_1,
  fileFormat: 'GeoTIFF',
  formatOptions: {
    cloudOptimized: true
  }
});
```



---

### Código en R de VCI

---

```
# VCI computation using chunking for large countries

#Enter the path to the a folder where you have enough
#free space
#to store your MODIS data and the resulting products
#Please do _not_ use backslashes ('\').
dataPath <- "C:/Users/Usuario/Downloads/EVI/"

# automatic download
downloadList<-"C:/Users/Desktop/Peru/download-list.txt"

#Quality masking: replace the '0' with a '1' to apply MODIS
#pixel reliability data. If you are not sure whether you
#should enable this option, it is recommended to leave it
#as is. Check the "in detail" page for more information.
cloudmask <- 1

#Change the capture of the VCI maps (jpg) according to your
#study area in line 224

#Setting VCI image colours

my_palette <- colorRampPalette(c('#8B0000', '#FF4500',
'#FFFF00', '#9ACD32', '#008000'))

#No need to enter more – mark the whole code (ctrl + a)
#and click on 'run' (or press ctrl + enter)

#####
```

```
####Installing all needed packages

install.packages("zoo")
install.packages("raster")
install.packages("curl")
install.packages("rgdal")

# calling packages for use

library(zoo)
library(raster)
library(curl)
library(rgdal)

#Downloading Files (except 'VI quality control' data as
#they are not needed)
#If you downloaded your data from appEEARS beforehand,
#comment out the following seven lines
files1 <- scan(downloadList, what='list', sep='\n')
for (d in 1:length(files1)){
  if (grepl("_VI_Quality_", files1[d]) == F){
    curl_download(url=files1[d],
      destfile=paste0(dataPath, "/", basename(files1[d])),
      quiet = T, handle = new_handle())
  }
  print(paste0('Downloading_source_data_(Step_1_of_4):',
    round(d / length(files1) * 100, digits=2), '%'))
}

#Creating a temp-directory and setting memory limit
dir.create(paste0(dataPath, '/temp/'))
rasterOptions(tmpdir=paste0(dataPath, '/temp/'))
rasterOptions(tolerance=1)
memory.limit(80000)

#Listing up all downloaded TIF-files in the data folder
rasterData <- list.files(path=dataPath, pattern='.tif$',
recursive=F, ignore.case=T, full.names=T)
rasterFiles <- basename(rasterData)

#Chunk-size for processing (in Pixel)
#You can reduce these numbers if you run into RAM-
#Problems early on:
#Try reducing the numbers to 1000. If you still run
#into RAM-problems, reduce to 500 or 250.
#Only reduce the numbers if you have memory issues
#("Error: cannot allocate vector of size [...]")
chwidth <- 1500
```

```
chheight <- 1500

#####STARTING EVI/VCI
#####

#Listing all EVI rasters and their corresponding pixel
#reliability data
EVIrasterData <- rasterData[grepl('EVI',rasterData)]
EVIqc
<- rasterData[grepl('pixel_reliability',rasterData)]

 #(Automatically adjusting chunk size for small scenes
#if needed)
initial <- raster(EVIrasterData[1])
if (as.numeric(ncol(initial)) <= chwidth ||
as.numeric(nrow(initial)) <= chheight){
  chwidth <- ceiling(ncol(initial)/2)
}

#Parsing all DOY and Years from the filenames
DOYs <- unique(substr(basename(EVIrasterData),38,40))
YEARS <- unique(substr(basename(EVIrasterData),34,37))

##VCI: chunkwise calculation
#Creating output folders
dir.create(paste0(dataPath,'/VCI'))
dir.create(paste0(dataPath,'/VCIjpg'))
dir.create(paste0(dataPath,'/EVI'))

#Determining chunk-shapefile

#Loading example image from the downloaded data
exRST <- raster(EVIrasterData[1])

#Determining chunks
h <- ceiling(ncol(exRST)/ceiling(ncol(exRST) /
chwidth))
v <- ceiling(nrow(exRST)/ceiling(nrow(exRST) /
chheight))

#Creating shapefile for each chunk
split <- aggregate(exRST,fact=c(h,v))
split[] <- 1:ncell(split)
splitshp <- rasterToPolygons(split)
names(splitshp) <- 'shapes'
notiles <- ncell(split)

#Filter values for quality masking: "0" and "1" in the pixel
```

```

#reliability bands are accepted as sufficient quality
goodValues <- c(0,1)

#Masking clouds/snow; Splitting data into chunks
for (d in 1:length(DOYs)){
  #Filtering all relevant data for this DOY
  vrasterData <-
  EVIrasterData[grepl(paste0(DOYs[d], '_aid'), EVIrasterData)]
  #..and their corresponding pixel reliability data
  vQC <- EVIqc[grepl(paste0(DOYs[d], '_aid'), EVIqc)]
  #Reading years of available data
  vYear <- substr(basename(vrasterData),34,37)
  for (y in 1:length(vYear)){
    viPRE <- raster(vrasterData[y])
    #Applying quality mask to each image (if masking
    #was activated)
    if (cloudmask == 1){
      qc <- raster(vQC[y])
      viPRE <- overlay(viPRE, qc, fun = function(x, y) {
        x[!(y %in% goodValues)] <- NA
        return(x)
      })
    }
    ##### Splitting (masked) data into Chunks
    for(i in 1:ncell(split)){
      ex <- extent(splitshp[splitshp$shapes==i,])
      exx <- crop(viPRE, ex)
      writeRaster(exx, filename=paste0(dataPath, '/temp/',
        DOYs[d], '_', vYear[y], '_EVICHUNK', formatC(i, width=3,
        flag='0')), format='GTiff', overwrite=TRUE)
    }
  }
  #(Progress report)
  print(paste0('Data_preparation_(VCI)_&_masking',
  _[(Step_2_of_4):_], round(d / length(DOYs) * 100,
  digits=2), '%'))
}

#Applying VCI calculation for each chunk
#List all chunks
EVIchunks <- list.files(path=paste0(dataPath, '/temp/'),
pattern='_EVICHUNK', recursive=F, ignore.case=T,
full.names=T)
for (d in 1:length(DOYs)){
  for (t in 1:ntiles){
    #Filtering relevant chunks for this specific date
    sEVIchunks <-
    EVIchunks[grepl(paste0(DOYs[d], '_'), EVIchunks)]
    sEVIchunks <-
    sEVIchunks[grepl(paste0('_EVICHUNK', formatC(t,

```

```

width=3, flag='0')) , sEVIchunks)]
#Listing years of data available for each DOY
vvYear <- substr(basename(sEVIchunks),5,8)

if (length(sEVIchunks) > 0){
  sT <- stack(sEVIchunks)

  #Removing filler-values from EVI data
  #The fill value for MODIS images is -3000
  sT[sT<(-2999)] <- NA

  #VCI formula application
  vimax <- stackApply(sT , rep(1, nlayers (sT)),
max, na.rm=T)
  vmin <- stackApply(sT , rep(1, nlayers (sT)),
min, na.rm=T)
  z <- vimax - vmin
  VCI <- ((sT -vimin)/z)*100

  #Writing VCI-chunks for each available year
  for (y in 1:length(vvYear)){
    writeRaster(VCI[[y]], filename=paste0(dataPath ,
      '/temp/' ,DOYs[d] , '_' ,vvYear[y] , '_VCICHUNK' ,
      formatC(t , width=3, flag='0')) ,format='GTiff' ,
      overwrite=TRUE)
  }
}

#(Progress report)
print(paste0('VCI_processing_(Step_3_of_4):_ ' ,
round(d / length(DOYs) * 100, digits=2), '%'))
}

##VCI chunk merging and output
#Listing all created chunks
VCIchunks <- list.files(path=paste0(dataPath , '/temp/' ) ,
pattern='_VCICHUNK' , recursive=F, ignore.case=T,
full.names=T)
#Looping through each available DOY_YEAR combination
for (y in 1:length(YEARs)){
  for (d in 1:length(DOYs)){
    #Listing relevant chunks (EVI, VCI) for this specific
date
    sVCIchunks <-
    VCIchunks[ grepl(paste0(DOYs[d] , '_' ,YEARs[y] , '_') ,
    VCIchunks)]
    sEVIchunks <-
    EVIchunks[ grepl(paste0(DOYs[d] , '_' ,YEARs[y] , '_') ,
    EVIchunks)]
    #Creating raster-list of the EVI chunks

```

```

if (length(sEVIchunks) > 0){
  if (length(sEVIchunks) > 1){
    sMos <- list()
    for (o in 1:length(sEVIchunks)){
      sMos <- append(sMos, raster(sEVIchunks[o]))
    }
    #Mosaicking the EVI chunks
    sMos$fun = mean
    Mos <- do.call(mosaic, sMos)
    Mos <- Mos*0.0001
    #Output of mosaicked, scaled EVI image
    writeRaster(Mos, filename=paste0(dataPath, '/EVI/',
    DOYs[d], '_', YEARs[y], '_EVI'), format='GTiff',
    overwrite=TRUE)
  } else {
    #Fail-safe in case only one chunk is available
    exp <- raster(sEVIchunks[1])
    exp <- exp*0.0001
    writeRaster(exp, filename=paste0(dataPath, '/EVI/',
    DOYs[d], '_', YEARs[y], '_EVI'), format='GTiff',
    overwrite=TRUE)
  }
}
#Creating raster-list of the VCI chunks
if (length(sVCIchunks) > 0){
  if (length(sVCIchunks) > 1){
    sMos <- list()
    for (o in 1:length(sVCIchunks)){
      sMos <- append(sMos, raster(sVCIchunks[o]))
    }
    #Mosaicking the VCI chunks
    sMos$fun = mean
    Mos <- do.call(mosaic, sMos)

    #Plotting JPG of VCI

    jpeg(filename=paste0(dataPath, '/VCIjpg/', DOYs[d],
    "_", YEARs[y], ".jpg", sep=""), quality = 100)

    plot(Mos,
          xlim=c(0,100),
          col=my_palette(101),
          # sets the colors as defined above
          main=paste("VCI", "_", (EVI)", "_sample_", DOYs[d],
          "_", YEARs[y], sep=""))
          # automizes the title of the plot.

    dev.off()

    #Output: final VCI mosaic

```

```
writeRaster(Mos, filename=paste0(dataPath, '/VCI/',
DOYs[d], '_', YEARS[y], '_VCI'), format='GTiff',
overwrite=TRUE)
} else {
  #Fail-safe in case only one chunk is available
  writeRaster(raster(sVCIchunks[1]),
  filename=paste0(dataPath, '/VCI/', DOYs[d], '_',
  YEARS[y], '_VCI'), format='GTiff', overwrite=TRUE)
}
}
print(paste0('EVI_output_&_VCI_output_(Step_4_of_4):
_____', round((d+(length(DOYs)*(y-1)))/(length(DOYs)*
length(YEARs))*100, digits=2), '%'))
}
}

#Removing temp files to free space
tmp <- list.files(path=paste0(dataPath, '/temp/'),
recursive=F, ignore.case=T, full.names=T)
file.remove(tmp)
```





## ANEXO E

Tabla de comprobación de remuestreo de píxel

	píxel 10 metros		píxel 100 metros					
Sitio	VV	VH	VV	VH	error VV	error VH	error VV %	error VH %
10	-11,19	-18,01	-10,03	-16,78	-1,16	-1,23	12%	7%
18	-9,21	-15,13	-9,22	-16,05	0,01	0,92	0%	6%
2	-9,75	-15,96	-9,96	-16,58	0,21	0,62	2%	4%
24	-7,63	-13,95	-9,44	-15,4	1,81	1,45	19%	9%
3	-12,16	-18,16	-10,58	-16,88	-1,58	-1,28	15%	8%
5	-10,76	-17,04	-9,85	-16,3	-0,91	-0,74	9%	5%
65	-8,62	-15,84	-9,44	-16,22	0,82	0,38	9%	2%
66	-8,63	-15,45	-9,96	-16,4	1,33	0,95	13%	6%
7	-11,25	-17,84	-11,71	-18,29	0,46	0,45	4%	2%
8	-12,4	-18,57	-10,66	-16,45	-1,74	-2,12	16%	13%
80	-7,45	-14,77	-9,39	-16,25	1,94	1,48	21%	9%
81	-8,66	-15,1	-9,74	-16,63	1,08	1,53	11%	9%
82	-10,77	-16,72	-10,97	-16,63	0,2	-0,09	2%	1%
83	-9,58	-16,77	-8,11	-15,28	-1,47	-1,49	18%	10%
88	-9,45	-16,66	-9,88	-16,55	0,43	-0,11	4%	1%
98	-11,12	-17,98	-12,47	-19,18	1,35	1,2	11%	6%
99	-11,08	-17,87	-12,36	-18,11	1,28	0,24	10%	1%
					4,06	2,16	10%	6%
					suma de los errores		promedio	