



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

MAPEO DE TURBERAS EN LA PATAGONIA CON SAR POLARIMÉTRICO DE BANDA L

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

LUCA LEPORATI CHIUMINATTO

PROFESOR GUÍA:
JAIME ORTEGA PALMA

MIEMBROS DE LA COMISIÓN:
FLORENCIO UTRERAS DÍAZ
PABLO ESTÉVEZ VALENCIA

SANTIAGO DE CHILE
2023

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO
POR: LUCA LEPORATI CHIUMINATTO
FECHA: 2023
PROF. GUÍA: JAIME ORTEGA PALMA

MAPEO DE TURBERAS EN LA PATAGONIA CON SAR POLARIMÉTRICO DE BANDA L

Las turberas cumplen, como muchos otros ecosistemas, un rol esencial en el desarrollo de la vida en la Tierra. Son garantes de una biodiversidad única, reguladoras del clima, permiten la acumulación de cuerpos de agua dulce y su filtrado, secuestran y almacenan el carbono de la atmósfera en la tierra, entre tantos otros, ahora llamados servicios ecosistémicos.

Quizás hoy, desde el apremio del cambio climático y la carrera por la carbono neutralidad, aquello que resulta más útil para justificar su protección, es mencionar su papel como activo reservorio de carbono. Es que las turberas, representando tan solo el 3 % de la superficie del planeta, contienen tanto carbono como toda la biomasa aérea del resto de los ecosistemas terrestres y casi la mitad del carbono que se encuentra en la atmósfera [1]. Asimismo, su drenaje o quema, contribuye con alrededor del 5 % de las emisiones anuales antropogénicas de dióxido de carbono [2].

En este Trabajo de Título, se desarrolla una herramienta de mapeo de turberas en la Patagonia, en base a polarimetría de radar de apertura sintética de banda L. En específico, se generan indicadores polarimétricos sobre un área de estudio y se implementan con ellos, diversos algoritmos de clasificación supervisada (Regresor Logístico, Red Neuronal y Bosque Aleatorio). Se discute la calidad del mapeo resultante de cada modelo, así como su capacidad de generalización.

Las turberas mapeadas son categorizadas en tres clases: Turberas Sphagnum, Otras Turberas y Turberas Impactadas. Siguiendo las directrices del IPCC para la confección de inventarios nacionales de gases de efecto invernadero [3], las dos primeras clases se consideran tierras no-gestionadas, mientras que la última es considerada como tierra gestionada.

Los algoritmos de Red Neuronal y Bosque Aleatorio alcanzan macro-métricas de Acierto, Precisión y Recuperación de 0,98 y 1,00 respectivamente, en la fase de entrenamiento. Mientras, en la fase de pruebas, donde se analiza la capacidad de generalización de los modelos, el último de ellos logra el mejor desempeño.

Se trata de una primera aproximación exploratoria a una iniciativa que surge desde la cooperación bilateral entre Chile y Argentina, donde se reafirma el potencial de los productos SAOCOM de banda L para la identificación de turberas en latitudes extremas.

Se espera que el trabajo realizado contribuya a la protección efectiva del ecosistema y que pueda, en un futuro, ser ampliado a mayores coberturas de territorio, para su uso como insumo de instrumentos nacionales de gestión del cambio climático.

*A mis ídolos
pelícanos.*

Agradecimientos

Enfrentarse al desafío de la enseñanza, de la carrera universitaria y en última instancia de este trabajo, ha sido siempre un desafío mayúsculo. Es que el camino de la educación tradicional y sobretodo de las ciencias, aquel que predica supuestas certezas, resulta a ratos vacío, revolviéndose en la búsqueda del sentido. Y lo que es peor, es que a veces nosotros en él, olvidamos lo importante. Y cuanta más armadura, más fácil olvidar la piel.

No maldigo la armadura. Sería absurdo no reconocer el privilegio de llevarla. Pero agradezco poder entenderla como algo circunstancial. Poder salir de la cobija universitaria sin que el premio nuble el recorrido. Espero, ser capaz también de soltarla, de dejarla tirada un rato en la orilla y remar sin su peso ni su permiso.

Este camino partió no hace seis, sino veinte años. Quién sabe cuándo uno lo decidió, si es que lo hizo realmente. Lo que sí, es que en él, tuve la suerte de cruzarme con tantos y tantas que atesoro profundamente y a los que van dedicadas estas hojas.

Primero, agradecer a mi familia. A mi abuela con su fuerza infinita, con su simpleza, su sabiduría. A mi mamá por su cuidado, su preocupación, su autenticidad. A mi papá por no conocer otra alternativa, por su empuje, su tozudez. A mi hermana por su tranquilidad y goce y a mi hermano, cómplice de aventuras, por ser el cable a la tierra de lo esencial. A mis primos, tíos y abuelas, que tantas veces sirvieron y servirán como ejemplo en esta vida. A mi familia perruna: a la Pimpa y la Luna por su alegría y cariño, al Black por su choreza y al Titán por su hermandad y tantas noches de compañía en el estudio.

Después, a mis amigos del colegio, con los que caminamos juntos por las vías de la niñez y adolescencia, compañeros de recreo y mundos imaginarios. Al Diego, el Renzo, el Nata, el Soto, el Macaco y el Emilio, gracias por nunca faltar.

Agradezco también, a los que se transformaron en mi motivación, en una excusa lo suficientemente importante para que flaquear en el camino universitario no fuese una alternativa. Al profe Novión, el Villena, la Julita y nuestro equipo. Al Paredes, el Juan, el Benja, el Chino, el Seba Silva, el Jairo, el Moli, el Pelao, el Seba Yáñez, el Emi, el Isma, el Jero, entre tantos otros con los que botamos a diario la basura, corriendo sin rumbo entre cuatro líneas.

A mis compañeros de Plan Común, de noches de desvelo, de frustraciones compartidas, de los pasos lentos en el camino que se hacía eterno. Al Brook, la Cami, la Cata Acevedo, la Coni, la Javi, el Joaco, el Max, el Pascal, el Pedro, el Rai Sandoval, la Sofi, la Dani, la Lula, el Sergio.

A mis guerreros del tramo final. Artillería pesada imbatible con corazón de oro. Al Ma-

niega, el Sami, el Werner, el Rai Vicente, el Rojas y nuestro capitán Pablito.

Gracias también a la profesora Maisa, que llegó en el minuto exacto de mi carrera universitaria y motivó tanto el desarrollo de este trabajo, como el reencanto con el futuro profesional. Al profesor Jaime Ortega y al profesor Florencio Utreras, que me recibieron y acompañaron de manera excepcional durante todo este año de trabajo.

Al Fabri y su familia, al Osvaldo. A mis hermanos de mar, por compartir la alegría de vivir, por recibirme siempre con los brazos abiertos y alimentar con fuerza el sueño que estoy viviendo.

A la Cami por su apoyo, su fuerza, su confianza, por su convicciones. Gracias por estos años de linda compañía, de crear juntos libremente la vida que queremos vivir.

Para no desteñir, me aseguré de estar entregando a última hora, así que sin duda varios se me quedaron en el tintero. Mis más sinceras gracias a todos los que estuvieron, están y seguirán estando en el camino, estoy eternamente agradecido con cada uno de ustedes.

De ahora en más, fuera de la madriguera, espero seguir cultivando mis sueños de niño, mi capacidad de dudar, de crear, de aprender libre. Seguir con la convicción del desarrollo como persona íntegra. De partir por el cuerpo, la mente, la naturaleza, la familia y los amigos.

Tabla de Contenido

1. Introducción	1
1.1. Introducción	1
1.1.1. Objetivo general	2
1.1.2. Objetivos específicos	2
2. Desarrollo	3
2.1. Marco Teórico	3
2.1.1. Contexto global	3
2.1.1.1. La evidencia del cambio climático	3
2.1.1.2. El clima futuro	6
2.1.1.3. Efectos del fenómeno	9
2.1.1.4. Limitar el cambio climático futuro	10
2.1.1.5. Directrices del IPCC para los inventarios nacionales de gases de efecto invernadero	11
2.1.2. Contexto normativo nacional	12
2.1.2.1. Contribución Determinada a Nivel Nacional (NDC) y Ley Marco de Cambio Climático	12
2.1.2.2. Ley de Protección de Turberas	15
2.1.3. Caracterización del objeto de estudio	17
2.1.4. Teoría Polarimétrica	19
2.1.4.1. Fundamentos	19
2.1.4.2. Geometría	21
2.1.4.3. Moteado	22
2.1.4.4. Teoremas de descomposición	22
2.1.4.5. Descomposición de Cloude y Pottier	23
2.1.4.6. Descomposición de Touzi	25
2.2. Estado del Arte	27
2.2.1. Mapeo del ecosistema en el territorio nacional.	27
2.2.2. Descomposición de Touzi para el mapeo de turberas.	28
2.3. Metodología	30
2.3.1. Enfoque	30
2.3.2. Etapas de desarrollo	30
2.4. Diseño	31
2.4.1. Insumos	31
2.4.1.1. Productos SAOCOM	31
2.4.1.2. Modelo de elevación digital	33
2.4.1.3. Área de estudio	33

2.4.1.4.	Definición de métricas	34
2.4.1.5.	Definición de clases a identificar en el mapeo.	35
2.4.1.6.	Polígonos de entrenamiento	36
2.4.2.	Desglose de hitos de cada fase	36
	Código y pruebas	36
	Implementación del clasificador	37
	Comentarios	37
	Discusión y planificación	37
2.5.	Resultados y Análisis	38
2.5.1.	Fase Código y pruebas	38
2.5.1.1.	Preprocesamiento	38
2.5.1.2.	Obtención de métricas.	39
2.5.1.3.	Exploración.	40
2.5.1.4.	Análisis.	47
2.5.1.4.1	Entropía.	47
2.5.1.4.2	Anisotropía.	48
2.5.1.4.3	Alfa.	49
2.5.1.4.4	Superficie.	49
2.5.1.4.5	Volumen.	50
2.5.1.4.6	Doble Rebote.	50
2.5.1.4.7	Phi.	51
2.5.1.4.8	Elevación, Pendiente, Orientación y Sombreado.	51
2.5.2.	Fase Implementación del clasificador	52
2.5.2.1.	Preprocesamiento.	52
2.5.2.2.	Generación de datos de entrenamiento y validación.	52
2.5.2.3.	Normalización de los datos.	52
2.5.2.4.	Definición y entrenamiento de algoritmos de clasificación su- pervisada a utilizar.	53
2.5.2.5.	Obtención y análisis de métricas de desempeño.	54
2.5.2.6.	Ampliación de la clasificación a toda el área de estudio.	57
2.6.	Discusión	65
2.6.1.	Fase Comentarios	65
2.6.1.1.	Preprocesamiento y obtención de métricas	65
2.6.1.2.	Entrenamiento y métricas de desempeño	65
2.6.1.3.	Ampliación al área de estudio	66
2.6.2.	Fase Discusión y planificación	67
2.6.2.1.	Evaluación de la aplicabilidad en instrumentos de gestión del cambio climático.	67
2.6.2.2.	Evaluación de la contribución a la protección	68
2.6.2.3.	Evaluación del uso de datos polarimétricos	68
2.6.2.4.	Discusión orientada a la generalización	68
3.	Conclusiones	70
	Bibliografía	72
	Anexos	75
A.	Exploración en detalle de métricas	75

A.1.	Anisotropía	75
	A.1.1. Mapas de Calor	75
	A.1.2. Funciones densidad de probabilidad	77
	A.1.3. Agrupados	78
	A.1.4. Resumen	78
A.2.	Alfa	78
	A.2.1. Mapas de Calor	79
	A.2.2. Funciones densidad de probabilidad	80
	A.2.3. Agrupados	82
	A.2.4. Resumen	82
A.3.	Superficie	82
	A.3.1. Mapas de Calor	83
	A.3.2. Funciones densidad de probabilidad	84
	A.3.3. Agrupados	86
	A.3.4. Resumen	86
A.4.	Volumen	86
	A.4.1. Mapas de Calor	87
	A.4.2. Funciones densidad de probabilidad	88
	A.4.3. Agrupados	90
	A.4.4. Resumen	90
A.5.	Doble Rebote	90
	A.5.1. Mapas de Calor	91
	A.5.2. Funciones densidad de probabilidad	92
	A.5.3. Agrupados	94
	A.5.4. Resumen	94
A.6.	Phi	94
	A.6.1. Mapas de Calor	95
	A.6.2. Funciones densidad de probabilidad	96
	A.6.3. Agrupados	98
	A.6.4. Resumen	98
A.7.	Elevación	98
	A.7.1. Mapas de Calor	99
	A.7.2. Funciones densidad de probabilidad	100
	A.7.3. Agrupados	102
	A.7.4. Resumen	102
A.8.	Pendiente	102
	A.8.1. Mapas de Calor	103
	A.8.2. Funciones densidad de probabilidad	104
	A.8.3. Agrupados	106
	A.8.4. Resumen	106
A.9.	Orientación	106
	A.9.1. Mapas de Calor	107
	A.9.2. Funciones densidad de probabilidad	108
	A.9.3. Agrupados	110
	A.9.4. Resumen	110
A.10.	Sombreado	110
	A.10.1. Mapas de Calor	111

A.10.2.	Funciones densidad de probabilidad	112
A.10.3.	Agrupados	114
A.10.4.	Resumen	114

Índice de Tablas

2.1.	Características técnicas SAOCOM [25].	32
2.2.	Características específicas del producto [25].	33
2.3.	Macro-métricas de desempeño del Regresor Logístico.	55
2.4.	Macro-métricas de desempeño de la Red Neuronal.	56
2.5.	Macro-métricas de desempeño del Bosque Aleatorio.	56
2.6.	Ranking de características en Bosque Aleatorio	57

Índice de Ilustraciones

2.1.	Esquema del lenguaje calibrado utilizado por el IPCC. Tomada de [7].	4
2.2.	Cambios en la temperatura global de superficie. Tomada de [8].	5
2.3.	Emisiones futuras según escenario de análisis. Tomada de [8].	7
2.4.	Indicadores de cambio climático global bajo los cinco escenarios descritos. Tomada de [8].	8
2.5.	Forzantes de impacto climático. Tomada de [8].	9
2.6.	Relación cuasi-lineal entre emisiones de CO ₂ acumuladas y aumento de temperatura global en superficie. Tomada de [8].	10
2.7.	Proceso de terrestización (a) y plaudificación (b). Tomada de [1].	17
2.8.	Estructura de una turbera. Tomada de [1].	18
2.9.	Esquema de propagación de una onda electromagnética. Tomada de [17].	19
2.10.	Ejemplo de polarización. Tomada de [17].	20
2.11.	Geometría SAR polarimétrico satelital. Tomada de [19].	22
2.12.	Parámetros de Touzi para humedal Mer Bleue. Tomada de [23].	28
2.13.	Esquema de metodología ágil.	30
2.14.	Área de estudio (Elaboración propia).	34
2.15.	Polígonos de entrenamiento (Elaboración propia).	36
2.16.	Mapa de calor de Entropía para polígonos de Turberas Sphagnum (Elaboración propia).	41
2.17.	Función densidad de probabilidad de Entropía en polígonos de Turberas Sphagnum (Elaboración propia).	41
2.18.	Mapa de calor de Entropía para polígonos de Otras Turberas (Elaboración propia).	42
2.19.	Función densidad de probabilidad de Entropía en polígonos de Otras Turberas (Elaboración propia).	42
2.20.	Mapa de calor de Entropía para polígonos de Turberas Impactadas (Elaboración propia).	43
2.21.	Función densidad de probabilidad de Entropía en polígonos de Turberas Impactadas (Elaboración propia).	43
2.22.	Entropía agrupada por clase (Elaboración propia).	44
2.23.	Entropía: Gráfico resumen (Elaboración propia).	44
2.24.	Resumen de métricas Entropía, Anisotropía y Alfa (Elaboración propia).	45
2.25.	Resumen de métricas Superficie, Volumen y Doble rebote (Elaboración propia).	46
2.26.	Resumen de métrica Phi (Elaboración propia).	46
2.27.	Resumen de métricas Elevación, Pendiente, Orientación y Sombreado (Elaboración propia).	47
2.28.	Matriz de confusión del Regresor Logístico (Elaboración propia).	54
2.29.	Desempeño Red Neuronal (Elaboración propia).	55

2.30.	Matriz de confusión del Bosque Aleatorio (Elaboración propia).	56
2.31.	Clasificación en base a Regresor Logístico con umbral de 0.5 (Elaboración propia).	58
2.32.	Clasificación en base a Regresor Logístico con umbral de 0.7 (Elaboración propia).	59
2.33.	Clasificación en base a Red Neuronal con umbral de 0.95 (Elaboración propia).	60
2.34.	Clasificación en base a Red Neuronal con umbral de 0.999 (Elaboración propia).	61
2.35.	Clasificación en base a Bosque Aleatorio con umbral de 0.7 (Elaboración propia).	62
2.36.	Clasificación en base a Bosque Aleatorio con umbral de 0.85 (Elaboración propia).	63
2.37.	Clasificación en base a Bosque Aleatorio con umbral de 0.95 (Elaboración propia).	64
A.1.	Mapa de calor de Anisotropía para polígonos de “Turberas Sphagnum” (Elaboración propia).	75
A.2.	Mapa de calor de Anisotropía para polígonos de “Otras Turberas” (Elaboración propia).	76
A.3.	Mapa de calor de Anisotropía para polígonos de “Turberas Impactadas” (Elaboración propia).	76
A.4.	Función densidad de probabilidad de Anisotropía en polígonos de “Otras Turberas” (Elaboración propia).	77
A.5.	Función densidad de probabilidad de Anisotropía en polígonos de “Turberas Sphagnum” (Elaboración propia).	77
A.6.	Función densidad de probabilidad de Anisotropía en polígonos de “Turberas Impactadas” (Elaboración propia).	78
A.7.	Anisotropía agrupada por clase (Elaboración propia).	78
A.8.	Anisotropía: Gráfico resumen (Elaboración propia).	78
A.9.	Mapa de calor de Alfa para polígonos de “Turberas Sphagnum” (Elaboración propia).	79
A.10.	Mapa de calor de Alfa para polígonos de “Otras Turberas” (Elaboración propia).	79
A.11.	Mapa de calor de Alfa para polígonos de “Turberas Impactadas” (Elaboración propia).	80
A.12.	Función densidad de probabilidad de Alfa en polígonos de “Otras Turberas” (Elaboración propia).	80
A.13.	Función densidad de probabilidad de Alfa en polígonos de “Turberas Sphagnum” (Elaboración propia).	81
A.14.	Función densidad de probabilidad de Alfa en polígonos de “Turberas Impactadas” (Elaboración propia).	81
A.15.	Alfa agrupada por clase (Elaboración propia).	82
A.16.	Alfa: Gráfico resumen (Elaboración propia).	82
A.17.	Mapa de calor de Superficie para polígonos de “Turberas Sphagnum” (Elaboración propia).	83
A.18.	Mapa de calor de Superficie para polígonos de “Otras Turberas” (Elaboración propia).	83
A.19.	Mapa de calor de Superficie para polígonos de “Turberas Impactadas” (Elaboración propia).	84
A.20.	Función densidad de probabilidad de Superficie en polígonos de “Otras Turberas” (Elaboración propia).	84

A.21. Función densidad de probabilidad de Superficie en polígonos de “Turberas Sphagnum” (Elaboración propia).	85
A.22. Función densidad de probabilidad de Superficie en polígonos de “Turberas Impactadas” (Elaboración propia).	85
A.23. Superficie agrupada por clase (Elaboración propia).	86
A.24. Superficie : Gráfico resumen (Elaboración propia).	86
A.25. Mapa de calor de Volumen para polígonos de “Turberas Sphagnum” (Elaboración propia).	87
A.26. Mapa de calor de Volumen para polígonos de “Otras Turberas” (Elaboración propia).	87
A.27. Mapa de calor de Volumen para polígonos de “Turberas Impactadas” (Elaboración propia).	88
A.28. Función densidad de probabilidad de Volumen en polígonos de “Otras Turberas” (Elaboración propia).	88
A.29. Función densidad de probabilidad de Volumen en polígonos de “Turberas Sphagnum” (Elaboración propia).	89
A.30. Función densidad de probabilidad de Volumen en polígonos de “Turberas Impactadas” (Elaboración propia).	89
A.31. Volumen agrupado por clase (Elaboración propia).	90
A.32. Volumen : Gráfico resumen (Elaboración propia).	90
A.33. Mapa de calor de Doble rebote para polígonos de “Turberas Sphagnum” (Elaboración propia).	91
A.34. Mapa de calor de Doble rebote para polígonos de “Otras Turberas” (Elaboración propia).	91
A.35. Mapa de calor de Doble rebote para polígonos de “Turberas Impactadas” (Elaboración propia).	92
A.36. Función densidad de probabilidad de Doble rebote en polígonos de “Otras Turberas” (Elaboración propia).	92
A.37. Función densidad de probabilidad de Doble rebote en polígonos de “Turberas Sphagnum” (Elaboración propia).	93
A.38. Función densidad de probabilidad de Doble rebote en polígonos de “Turberas Impactadas” (Elaboración propia).	93
A.39. Doble rebote agrupado por clase (Elaboración propia).	94
A.40. Doble rebote : Gráfico resumen (Elaboración propia).	94
A.41. Mapa de calor de Phi para polígonos de “Turberas Sphagnum” (Elaboración propia).	95
A.42. Mapa de calor de Phi para polígonos de “Otras Turberas” (Elaboración propia).	95
A.43. Mapa de calor de Phi para polígonos de “Turberas Impactadas” (Elaboración propia).	96
A.44. Función densidad de probabilidad de Phi en polígonos de “Otras Turberas” (Elaboración propia).	96
A.45. Función densidad de probabilidad de Phi en polígonos de “Turberas Sphagnum” (Elaboración propia).	97
A.46. Función densidad de probabilidad de Phi en polígonos de “Turberas Impactadas” (Elaboración propia).	97
A.47. Phi agrupada por clase (Elaboración propia).	98
A.48. Phi: Gráfico resumen (Elaboración propia).	98

A.49.	Mapa de calor de Elevación para polígonos de “Turberas Sphagnum” (Elaboración propia).	99
A.50.	Mapa de calor de Elevación para polígonos de “Otras Turberas” (Elaboración propia).	99
A.51.	Mapa de calor de Elevación para polígonos de “Turberas Impactadas” (Elaboración propia).	100
A.52.	Función densidad de probabilidad de Elevación en polígonos de “Otras Turberas” (Elaboración propia).	100
A.53.	Función densidad de probabilidad de Elevación en polígonos de “Turberas Sphagnum” (Elaboración propia).	101
A.54.	Función densidad de probabilidad de Elevación en polígonos de “Turberas Impactadas” (Elaboración propia).	101
A.55.	Elevación agrupada por clase (Elaboración propia).	102
A.56.	Elevación: Gráfico resumen (Elaboración propia).	102
A.57.	Mapa de calor de Pendiente para polígonos de “Turberas Sphagnum” (Elaboración propia).	103
A.58.	Mapa de calor de Pendiente para polígonos de “Otras Turberas” (Elaboración propia).	103
A.59.	Mapa de calor de Pendiente para polígonos de “Turberas Impactadas” (Elaboración propia).	104
A.60.	Función densidad de probabilidad de Pendiente en polígonos de “Otras Turberas” (Elaboración propia).	104
A.61.	Función densidad de probabilidad de Pendiente en polígonos de “Turberas Sphagnum” (Elaboración propia).	105
A.62.	Función densidad de probabilidad de Pendiente en polígonos de “Turberas Impactadas” (Elaboración propia).	105
A.63.	Pendiente agrupada por clase (Elaboración propia).	106
A.64.	Pendiente: Gráfico resumen (Elaboración propia).	106
A.65.	Mapa de calor de Orientaci´ para polígonos de “Turberas Sphagnum” (Elaboración propia).	107
A.66.	Mapa de calor de Orientación para polígonos de “Otras Turberas” (Elaboración propia).	107
A.67.	Mapa de calor de Orientación para polígonos de “Turberas Impactadas” (Elaboración propia).	108
A.68.	Función densidad de probabilidad de Orientación en polígonos de “Otras Turberas” (Elaboración propia).	108
A.69.	Función densidad de probabilidad de Orientación en polígonos de “Turberas Sphagnum” (Elaboración propia).	109
A.70.	Función densidad de probabilidad de Orientación en polígonos de “Turberas Impactadas” (Elaboración propia).	109
A.71.	Orientación agrupada por clase (Elaboración propia).	110
A.72.	Orientación: Gráfico resumen (Elaboración propia).	110
A.73.	Mapa de calor de Sombreado para polígonos de “Turberas Sphagnum” (Elaboración propia).	111
A.74.	Mapa de calor de Sombreado para polígonos de “Otras Turberas” (Elaboración propia).	111

A.75.	Mapa de calor de Sombreado para polígonos de “Turberas Impactadas” (Elaboración propia).	112
A.76.	Función densidad de probabilidad de Sombreado en polígonos de “Otras Turberas” (Elaboración propia).	112
A.77.	Función densidad de probabilidad de Sombreado en polígonos de “Turberas Sphagnum” (Elaboración propia).	113
A.78.	Función densidad de probabilidad de Sombreado en polígonos de “Turberas Impactadas” (Elaboración propia).	113
A.79.	Sombreado agrupada por clase (Elaboración propia).	114
A.80.	Sombreado: Gráfico resumen (Elaboración propia).	114

Capítulo 1

Introducción

1.1. Introducción

En el año 1997, un grupo de países, en su mayoría desarrollados, convenían en el Protocolo de Kyoto (de la Convención Marco de las Naciones Unidas Sobre el Cambio Climático) la persecución conjunta de una serie de objetivos, a fin de promover el desarrollo sostenible [4]. Quedaban cuantificados allí entonces, los primeros compromisos nacionales en términos de reducción de emisiones antropogénicas de gases de efecto invernadero (GEI).

A menos de 30 años de lo que no parecía ser más que una tibia instancia de cooperación internacional, el desafío del tiempo presente cobra una dimensión órdenes de magnitud mayor.

En estos días, la llamada Carbono neutralidad ha abanderado una inédita lucha por el cambio climático y no es de extrañar, considerando la dramática y voluminosa evidencia científica que alerta sobre su importancia. Sin embargo, el problema que nos ha arrastrado hasta aquí tiene sus inicios aún más arraigados en nuestro haber como sociedad.

El conflicto del cambio climático responde a un modelo de desarrollo fallido, que pretendió existir, o por ignorancia o por audacia, de espaldas al entorno natural que todo lo vio nacer. Entenderlo como un síntoma del divorcio del ser humano con su entorno y no como la enfermedad misma, nos permitirá realmente avanzar como sociedad hacia la reconciliación con el mundo natural.

Dentro del enorme desafío de la mitigación y adaptación a los efectos del cambio climático, que han empujado a Chile y el mundo a una estrecha agenda de refundaciones, ha surgido con urgencia la necesidad de identificación, comprensión y protección de los ecosistemas. Un esfuerzo en el cual el desarrollo de la ciencia y la utilización de herramientas tecnológicas cumple un rol de vital importancia.

El presente Trabajo de Título ataca un problema desprendido del cambio climático y, por ende, indivisiblemente, del conflicto humano-naturaleza. El objeto de estudio en cuestión son las turberas de la Patagonia: grandes extensiones de prístinos humedales que brindan importantes servicios ecosistémicos incluyendo la regulación del agua, la conservación de biodiversidad y el secuestro y almacenamiento de carbono.

1.1.1. Objetivo general

El objetivo general del trabajo consiste en desarrollar una herramienta para el mapeo de turberas en la Patagonia (ubicadas en Chile y Argentina), aplicando técnicas de polarimetría SAR de banda L e inteligencia computacional. Se espera contribuir con ella a un mapeo preciso del ecosistema, que no existe actualmente y es esencial para la comprensión y por sobre todo, la protección efectiva del mismo.

1.1.2. Objetivos específicos

A continuación se listan los objetivos específicos del Trabajo de Título.

- Desarrollar una herramienta de clasificación y mapeo, que permita identificar turberas en un área de estudio acotada dentro de la Patagonia, con un porcentaje de aciertos, precisión y recuperación mayores a 95 % sobre los píxeles etiquetados.
- Evaluar cualitativamente la capacidad de generalización de la herramienta, en base a la generación de mapas georreferenciados y su comparación con imágenes satelitales de alta resolución.
- Categorizar las turberas a mapear en sub-clases, que sean de utilidad para instrumentos nacionales de gestión del cambio climático, tales como el Sistema nacional de inventarios de gases de efecto invernadero.
- Mostrar la factibilidad de clasificación y mapeo de turberas en la zona, en base a los productos SAOCOM disponibles.

El tiempo destinado a la materialización de cada uno de dichos objetivos, es desde enero del año 2022 a marzo del 2023.

Sobre el desarrollo en general del presente Trabajo de Título, se persigue que la información generada se atenga a los lineamientos dispuestos por el Panel Intergubernamental Para el Cambio Climático (IPCC) a la fecha y, por ende, y según lo establecido en el artículo 28 de la Ley Marco de Cambio Climático [5], a la legislación chilena.

En una fase inicial, correspondiente al desarrollo del presente Trabajo de Título, se recopilan productos de polarimetría SAR junto con información georreferenciada descrita por expertos, delimitada a un sector de estudio específico. En base a ello, se desarrolla una herramienta que permite identificar turberas de manera efectiva en el área de estudio.

Para una segunda etapa de desarrollo, que queda fuera de los alcances del presente Trabajo de Título, se propone la generalización de la herramienta a una mayor extensión del territorio. Aún cuando la implementación de esta etapa no forma parte del presente Trabajo de Título, el ciclo de trabajo realizado apunta inherentemente hacia ella y, por ende, están íntimamente relacionadas.

Capítulo 2

Desarrollo

2.1. Marco Teórico

2.1.1. Contexto global

Enmarcado el presente Trabajo de Título en el desafío multilateral de la lucha contra el cambio climático, no podría hacer caso omiso a las ya existentes instituciones e iniciativas internacionales que cumplen un esfuerzo inédito por abarcar un problema que permea innumerables áreas de la vida humana, en todos los rincones del planeta.

En ese sentido, el IPCC, organismo encargado de evaluar y sistematizar el desarrollo científico en torno al cambio climático y sus potenciales efectos medioambientales y socio-económicos, cumple un rol clave al homogeneizar los esfuerzos para combatir un conflicto de magnitud y transversalidad posiblemente nunca antes evidenciado en escala humana.

Lo que convoca entonces, es realizar un trabajo coherente con la evidencia científica y los lineamientos dispuestos por este organismo.

2.1.1.1. La evidencia del cambio climático

El IPCC, creado en el año 1988 por el Programa de Medioambiente de Naciones Unidas (UNEP), la Organización Mundial Meteorológica (WMO) y la Asamblea General de Naciones Unidas, cumple con revisar y evaluar el conocimiento científico más reciente sobre la materia, mas no produce por sí mismo investigación alguna.

Definida en su declaración de principios, la función del IPCC consiste en “... analizar, de forma exhaustiva, objetiva, abierta y transparente la información científica, técnica y socio-económica relevante para entender la base científica del riesgo que supone el cambio climático provocado por la actividad humana, sus posibles repercusiones y las opciones que existen para adaptarse al cambio climático y atenuar sus efectos” [6]. Los informes producidos por el organismo son “...neutrales desde el punto de vista político, aunque es posible que deban abordar de forma objetiva factores socioeconómicos, científicos y técnicos relevantes para la aplicación de ciertas políticas específicas” [6].

El IPCC ha desarrollado para su labor el denominado “lenguaje calibrado”, que permite asociar a cada declaración incluida en sus reportes, un determinado nivel de confianza en la misma, basada en el entendimiento de la información científica disponible a la fecha.

Las expresiones cualitativas, denominadas escala de confianza, describen la validez de los hallazgos basados en el tipo, calidad, consistencia y grado de acuerdo en diferentes líneas de evidencia [7]. Así, son catalogados en muy baja, baja, media, alta o muy alta confianza, como se pueden observar en el Paso 2 de la Figura 2.1.

Por su parte, cuando existen suficientes datos y confianza para asignar a los hallazgos una estimación cuantitativa o probabilística [7], se utiliza la denominada escala de probabilidad. Como se puede observar en el Paso 3 de la Figura 2.1, existe una amplia variedad de conceptos en dicha escala y su probabilidad puede estar asociada a extremos de las funciones de distribución de probabilidad (nivel estadístico), o a regiones centrales de las mismas (rango estadístico).

En la Figura 2.1 se pueden encontrar ejemplos de uso de cada uno de los tipos de expresiones anteriormente mencionadas.

En lo sucesivo, se dará una pincelada por algunos de los hallazgos más recientes y relevantes sistematizados por el organismo, para introducir brevemente al lector en el conflicto en que se encuentra inmerso el Trabajo de Título. En varios de ellos, se utiliza el sistema de lenguaje calibrado descrito.

Entrando de lleno a algunas de las evidencias más clarificadoras sobre el cambio climático, el Grupo de Trabajo 1 del IPCC (WGI), abocado a las bases de las ciencias físicas del

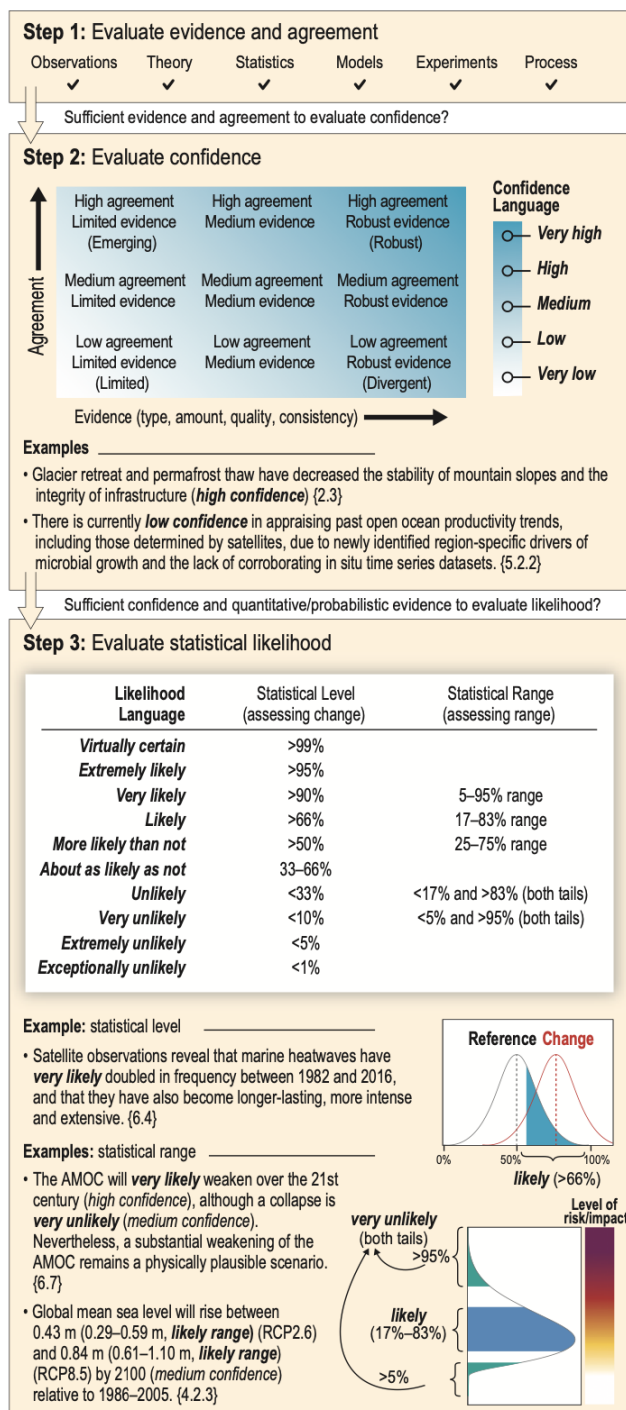


Figura 2.1: Esquema del lenguaje calibrado utilizado por el IPCC. Tomada de [7].

fenómeno, en el Resumen para Tomadores de Decisiones (SPM) de su Sexto informe de Evaluación (AR6), afirma que “es inequívoco que la influencia humana ha calentado la atmósfera, el océano y la tierra. Han ocurrido cambios extendidos y rápidos en la atmósfera, el océano, la criosfera y la biosfera”[8].




Figura 2.2: Cambios en la temperatura global de superficie. Tomada de [8].

En la Figura 2.2 (a), se presenta una reconstrucción desde archivos paleoclimáticos y observación directa de la variable cambio de temperatura global en superficie (en promedio decadal) a lo largo de los años. El sombreado gris con líneas diagonales blancas muestra los rangos muy probables para las reconstrucciones de temperatura.

En ella, se puede observar que desde el período preindustrial, el aumento de temperatura ha sido dramático, sostenido y sin precedentes en más de 2.000 años. Más aún, la barra vertical de la izquierda muestra la temperatura estimada (en un rango muy probable) del período de varios siglos más cálido en los últimos 100.000 años. Este período, a diferencia del presente, fue causado por variaciones orbitales lentas, de varios milenios.

En la Figura 2.2 (b), se observa el cambio en la temperatura global de superficie en promedio anual en los últimos 170 años. La curva negra muestra la temperatura observada; la café, muestra la respuesta de temperatura a forzantes humanos y naturales obtenida en la simulación de modelo climático CMIP6 (por sus siglas Coupled Model Intercomparison Project Phase 6); y, la verde, muestra la respuesta solo ante forzantes naturales, de la misma simulación. Por su parte, las zonas sombreadas muestran el rango muy probable de las simulaciones mencionadas.

En el lenguaje calibrado del organismo, se estima que el rango probable del aumento de temperatura global de superficie provocado por el ser humano desde 1850-1900 a 2010-2019 está entre $0.8^{\circ}C$ y $1.3^{\circ}C$ [8].

Si bien la elección de la variable temperatura a la hora de evidenciar el cambio climático resulta intuitiva, no hay que olvidar que el estado del clima y, por ende, los efectos del fenómeno en proceso, trascienden largamente el análisis respecto de esta única variable. Es el Sistema Tierra en su conjunto que presenta afectaciones y sus evidencias han sido observadas mediante diversas variables de estudio, en diversos fenómenos.

Según [8], la escala de los cambios recientes en el sistema climático en su conjunto - y el estado actual de muchos aspectos del mismo - no tienen precedentes durante muchos siglos a miles de años.

2.1.1.2. El clima futuro

Un conjunto de cinco escenarios de emisiones de gases de efecto invernadero a escala planetaria son considerados actualmente por el organismo, con el objetivo de explorar la respuesta climática del Sistema Tierra en cada uno de ellos.

Se definen escenarios de emisiones altas y muy altas (*SSP3* – 7.0 y *SSP5* – 8.5), con emisiones de CO₂ que casi duplican las actuales para el período de 2100 y 2050, respectivamente; un escenario con emisiones intermedias (*SSP2* – 4.5), manteniéndose en emisiones de CO₂ similares a los niveles actuales hasta mediados de siglo; y escenarios con muy bajas y bajas emisiones de GEI, disminuyendo las emisiones de carbono a cero neto alrededor o después de 2050, seguido de niveles variables de emisiones netas negativas de carbono (*SSP1* – 1.9 y *SSP1* – 2.6, respectivamente)[8].

En la Figura 2.3 se puede observar el comportamiento en específico de las emisiones futuras en cada escenario en cuestión. Se presentan emisiones de dióxido de carbono, metano, óxido nitroso y dióxido de azufre.

Siendo ampliamente reconocida la relación presente entre las emisiones de GEI y el cambio climático, se evalúa en cada uno de los escenarios anteriormente descritos, el estado y evolución del clima. En la Figura 2.4 por ejemplo, se puede observar el comportamiento de algunas variables o indicadores de cambio climático global dentro de cada escenario anteriormente comentado.

(a) Future annual emissions of CO₂ (left) and of a subset of key non-CO₂ drivers (right), across five illustrative scenarios




Figura 2.3: Emisiones futuras según escenario de análisis. Tomada de [8].

En la parte (a) de la Figura 2.4, se observa el cambio en la temperatura de superficie global relativo al período 1850-1900. Estos cambios son obtenidos mediante modelos de simulación CMIP6, tanto en simulaciones históricas (curva negra) como futuras. Se muestran, además, rangos muy probables para las simulaciones *SSP1 – 2.6* y *SSP3 – 7.0*.

En la parte (b), se observa el área de hielo marino del Ártico de septiembre, relativo al mismo período, basado en modelos de simulación CMIP6. En la curva negra se observan simulaciones históricas y se muestran rangos muy probables para las simulaciones *SSP1 – 2.6* y *SSP3 – 7.0*.

En la parte (c), se grafica el pH global del océano en superficie, para el mismo período, también basado en modelos de simulación CMIP6. Nuevamente, se observan simulaciones históricas en la curva negra y se muestran rangos muy probables para las simulaciones *SSP1 – 2.6* y *SSP3 – 7.0*.

En la parte (d), se presentan tanto observaciones (en la curva negra) como resultados de modelos de simulación CMIP6 para la variable cambio del nivel global promedio del mar respecto al año 1900. Lo anterior durante el mismo período analizado previamente. Se muestran rangos probables para las simulaciones *SSP1 – 2.6* y *SSP3 – 7.0*.

Finalmente, en la parte (e), se muestra el cambio del nivel global promedio del mar en el año 2300 respecto al año 1900. Se muestran los resultados obtenidos para las simulaciones *SSP1 – 2.6* y *SSP5 – 8.5*, sombreados entre los percentiles 17 y 83.

Las tendencias arrojadas en la Figura 2.4, muestran un panorama impactante. El aumento

de la temperatura promedio global en superficie, el deshielo, la acidificación del océano y el aumento del nivel del mar desde 1950 al 2100 son una característica compartida y aparentemente ineludible cualquiera sea la trayectoria de emisiones de gases de efecto invernadero que se siga como humanidad. Sin embargo, se evidencia que la magnitud y velocidad del cambio de cada variable, cambian de manera sustancial según el escenario que se trate.

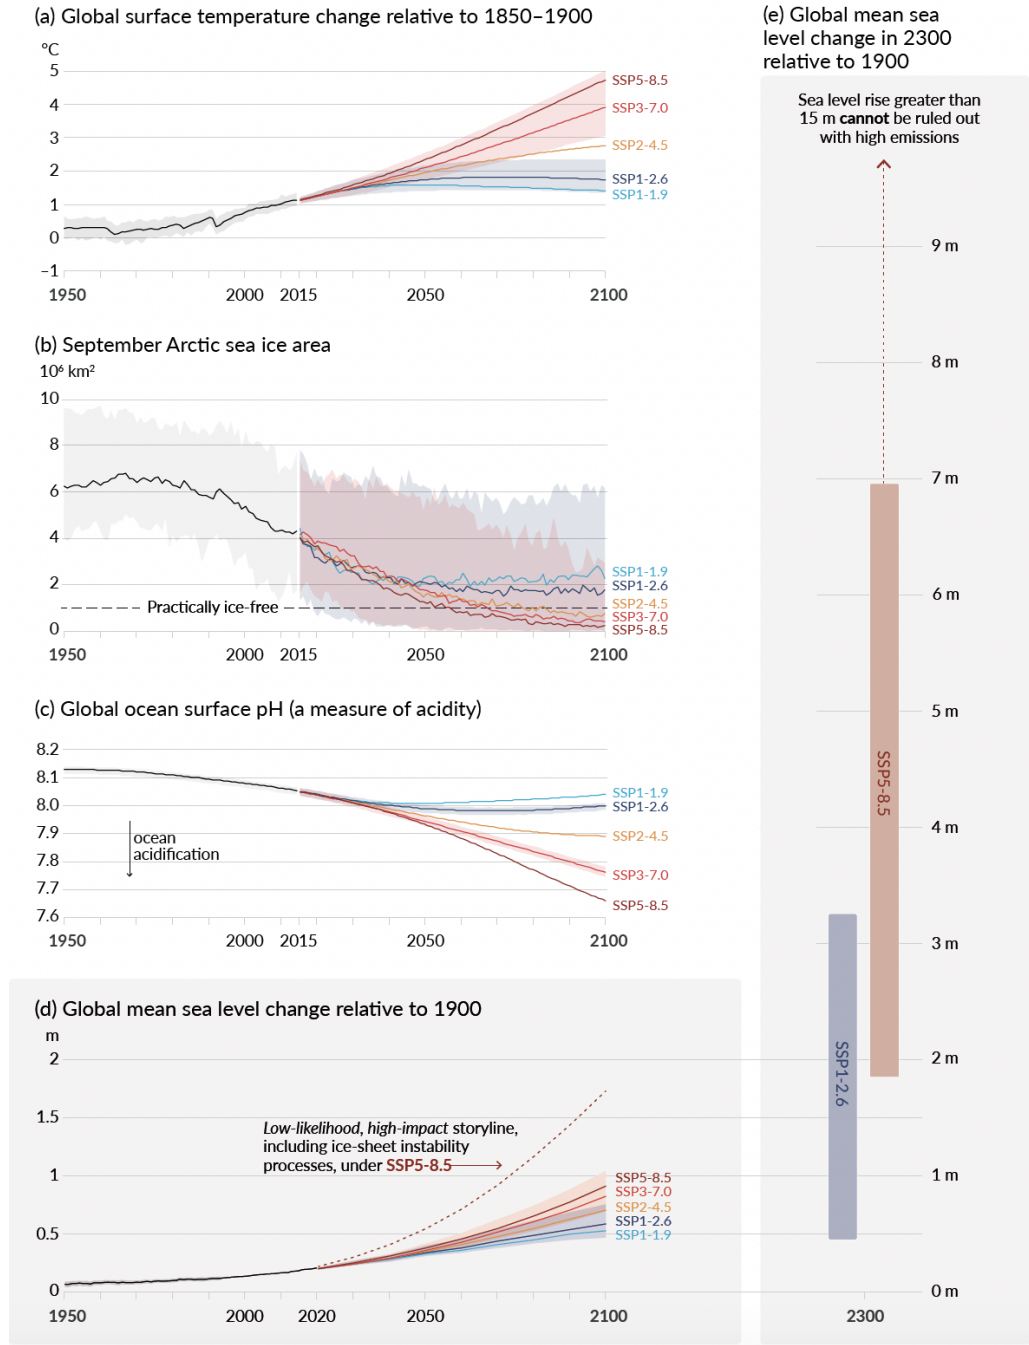


Figura 2.4: Indicadores de cambio climático global bajo los cinco escenarios descritos. Tomada de [8].

Es importante destacar, que como se puede intuir, muchos de los cambios debidos a las

emisiones pasadas y futuras de gases de efecto invernadero son irreversibles durante siglos o milenios. Especialmente, los cambios en el océano, las capas de hielo y el nivel global del mar [8].

2.1.1.3. Efectos del fenómeno

Como se puede corroborar en la Figura 2.4 (a), la temperatura global en superficie continuará aumentando al menos hasta mediados de siglo bajo todos los escenarios considerados [8].

Lo anterior, resulta especialmente relevante si se considera que, como en el mismo reporte se asevera, con cada incremento adicional del calentamiento global, los cambios en los eventos extremos siguen aumentando [8]. Ellos incluyen aumentos en la frecuencia e intensidad de los eventos de calor extremos, olas de calor marinas, fuertes precipitaciones y, en algunas regiones, sequías agrícolas y ecológicas, aumento en la proporción de ciclones tropicales intensos, reducciones en el hielo marino, la cobertura de nieve y el *permafrost* del Ártico [8].

Para evaluar de manera efectiva la amplia gama de efectos que tiene en el Sistema Tierra el desarrollo del fenómeno en cuestión, se han definido los llamados forzantes de impacto climático (CID).

Los forzantes de impacto climático (CID) son condiciones físicas del sistema climático (como medias, eventos, extremos) que afectan a un elemento de la sociedad o ecosistema. Estos son agrupados según diversas categorías, según se puede observar en la Figura 2.5.

Si bien cada uno de ellos requiere una detención y tratamiento especial, para efectos de la presente contextualización, cuyo objetivo es interiorizar al lector en la dimensión del problema en cuestión, basta con mencionar el siguiente hallazgo:




Figura 2.5: Forzantes de impacto climático. Tomada de [8].

Con el aumento del calentamiento global, se prevé que todas las regiones del planeta experimenten aumentos en los forzantes de impacto climático cálidos y disminuciones en los fríos (confianza alta en lenguaje calibrado). Estos cambios serían más generalizados a 2°C en

comparación con 1,5°C de calentamiento global e incluso más generalizado y/o pronunciado para mayores niveles de calentamiento [8].

Esta declaración refuerza la urgencia de limitar el calentamiento global a la brevedad y a la menor magnitud posible.

2.1.1.4. Limitar el cambio climático futuro

Entendido el conflicto del cambio climático como producto de la acción humana, pudiendo dimensionar la magnitud y dificultosa reversibilidad del fenómeno y comprendiendo sus transversales impactos sobre el Sistema Tierra y la vida en general, es preciso escudriñar en las posibilidades de limitar dicho fenómeno.

Una de las evidencias más renombradas al respecto, con justa razón por su sencilla lucidez, es la existencia de una relación prácticamente lineal entre las emisiones acumuladas de dióxido de carbono y la temperatura global en superficie, desde el año 1850 a la fecha.

Global surface temperature increase since 1850–1900 (°C) as a function of cumulative CO₂ emissions (GtCO₂)

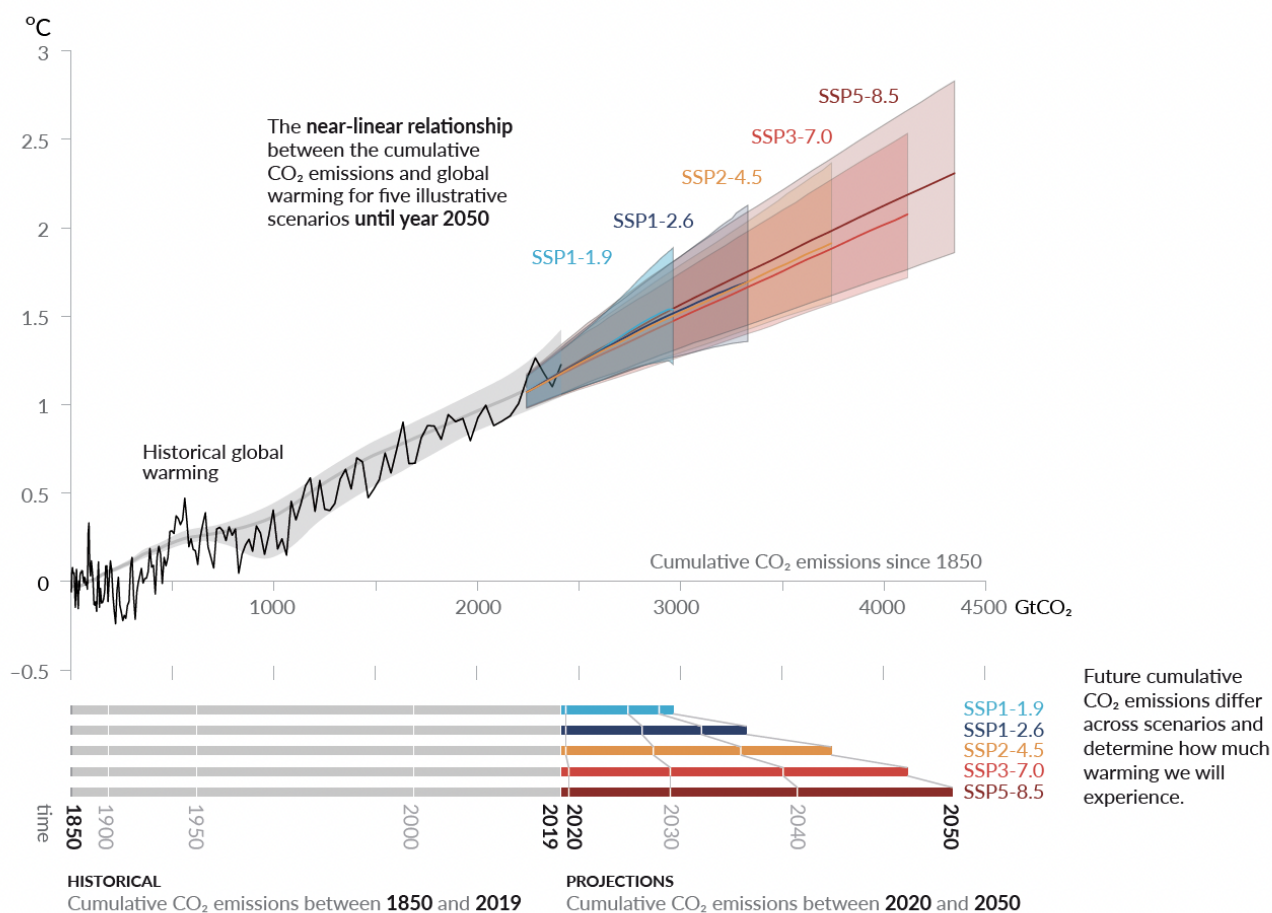


Figura 2.6: Relación cuasi-lineal entre emisiones de CO₂ acumuladas y aumento de temperatura global en superficie. Tomada de [8].

En la Figura 2.6, los datos históricos (línea negra delgada) muestran el aumento observado de la temperatura superficial global en $^{\circ}C$ desde 1850–1900, como una función de las emisiones históricas de CO_2 acumuladas $GtCO_2$ desde 1850 hasta 2019. El rango gris con su línea central muestra una estimación correspondiente al calentamiento de la superficie causada por el ser humano. Las áreas coloreadas muestran el rango evaluado como muy probable en las diferentes proyecciones de temperatura global de la superficie y las líneas centrales coloreadas gruesas, muestran la mediana estimada desde 2020 hasta el año 2050. La relación se ilustra sobre el dominio de las emisiones acumuladas de CO_2 para las cuales las emisiones globales de CO_2 siguen siendo netas positivas [8].

La consecuencia directa de la relación presentada, es que estabilizar el aumento de temperatura global inducido por el ser humano (a cualquier nivel) implica necesariamente alcanzar el valor cero de emisiones netas antropogénicas de CO_2 [8].

Bajo el entendido que es de imperiosa necesidad detener el calentamiento, este hallazgo se ha transformado quizás en uno de los más relevantes y controvertidos de la época. Limitar las emisiones acumuladas de dióxido de carbono a la atmósfera a un determinado presupuesto como humanidad es la tarea. La consigna es carbono neutralidad.

2.1.1.5. Directrices del IPCC para los inventarios nacionales de gases de efecto invernadero

En la presente sección, se detallan las principales directrices del IPCC sobre la creación de inventarios nacionales de gases de efecto invernadero. En específico, se tratan aquellas directrices relativas al sector Agricultura, silvicultura y otros usos de la tierra, en su apartado de Humedales.

El uso y la gestión de la tierra tiene influencia sobre una diversidad de procesos del ecosistema que afectan a los flujos de los gases de efecto invernadero, tales como la fotosíntesis, la respiración, la descomposición, la nitrificación/desnitrificación, la fermentación entérica y la combustión. Estos procesos incluyen transformaciones del carbono y del nitrógeno provocadas por los procesos biológicos (actividad de microorganismos, plantas y animales) y físicos (combustión, lixiviación y escurrimiento)[3].

En el volumen cuatro del documento Directrices del IPCC de 2006 para los inventarios nacionales de gases de efecto invernadero, denominado Agricultura, silvicultura y otros usos de la tierra (AFOLU) [3] se detallan diversos procedimientos metodológicos que guían la elaboración de inventarios nacionales de gases de efecto invernadero en dicho sector productivo. Para este fin, se categoriza el uso y gestión de la tierra en seis categorías principales: Tierras forestales, Tierras de cultivo, Pastizales, Humedales, Asentamientos y Otras tierras.

Para efectos del desarrollo de inventarios nacionales de gases de efecto invernadero, en el sector AFOLU, se consideran únicamente aquellas tierras que son consideradas gestionadas, es decir, aquellas en las que ha habido intervención humana y donde se han aplicado prácticas para la realización de actividades de producción, ecológicas o sociales [3].

Así, cada una de las categorías de uso de la tierra se subdivide en la tierra remanente

en esa categoría (por ejemplo, tierras forestales que permanecen como tales) y la tierra que se convierte de una categoría a otra (por ejemplo, tierra forestal que se convierte en tierra de cultivo). Las emisiones y absorciones de gases de efecto invernadero determinadas para cada uso específico de la tierra incluyen el CO₂ (a medida que se modifican las existencias de carbono) de la biomasa, la materia orgánica muerta y los suelos, así como emisiones de otros gases provenientes del quemado y, según la categoría de uso de la tierra, emisiones de otras fuentes específicas (por ejemplo, emisiones de CH₄ del arroz) [3].

Los humedales son definidos en [3] como todo tipo de tierras que estén cubiertas o saturadas por agua durante todo el año o la mayor parte de él. En específico, se definen los humedales gestionados como aquellos en que el nivel freático se modifica artificialmente (se drene o eleve) o que han sido creados por actividad humana (como el embalsado de un río).

Así, se suministran metodologías de estimación de emisión y absorción de gases de efecto invernadero para Bonales (que para efectos del presente Trabajo son equivalentes a las turberas) liberados y drenados para la producción de turba y para tierras inundadas permanentemente. En cada una de ellas se consideran casos en que el ecosistema gestionado permanece como tal y casos en que hay un proceso de conversión de la tierra que involucra la categoría respectiva.

Si bien el objetivo central del presente Trabajo de Título no es realizar una estimación de las emisiones y absorciones de GEI ocurridas en las turberas de la Patagonia, se busca que la información producida sirva de insumo para dichos fines.

En base a la presente recopilación, se establece que el mapeo realizado y su implementación, debe permitir la clasificación la superficie en tierras gestionadas y no gestionadas.

De esta manera, se contribuye con el desarrollo de indicadores coherentes con las directrices dispuestas por el IPCC en la materia y, por ende, aplicables en diversos instrumentos de gestión climática nacional, como, por ejemplo, el Presupuesto nacional de emisiones de gases de efecto invernadero al año 2030 y 2050 (descrito en detalle en la Ley Marco de Cambio Climático [5]).

2.1.2. Contexto normativo nacional

2.1.2.1. Contribución Determinada a Nivel Nacional (NDC) y Ley Marco de Cambio Climático

En el año 2016, Chile suscribió el Acuerdo de París, que exige desarrollar periódicamente un instrumento denominado Contribución Determinada a Nivel Nacional (NDC).

En él, se estipulan los principales compromisos adquiridos por el país relativos a su acción climática, en la búsqueda por detener el aumento de la temperatura promedio global, de aumentar la resiliencia del planeta y de movilizar inversiones públicas y privadas en la senda de un desarrollo sostenible, que considere las variables ambientales, sociales y económicas de manera equilibrada [9].

Este compromiso del país para con la lucha contra el cambio climático, tiene su directo correlato, además, en la legislación vigente.

El 30 de Mayo del 2022, fue promulgada la Ley Marco de Cambio Climático, que tiene por objeto hacer frente a los desafíos que presenta el cambio climático, transitar hacia un desarrollo bajo en emisiones de gases de efecto invernadero y otros forzantes climáticos, hasta alcanzar y mantener la neutralidad de emisiones de gases de efecto invernadero al año 2050, adaptarse al cambio climático, reduciendo la vulnerabilidad y aumentando la resiliencia a los efectos adversos del cambio climático y dar cumplimiento a los compromisos internacionales asumidos por el Estado de Chile en la materia [5].

Para el cumplimiento del objeto de esta ley, se designa la Estrategia Climática de Largo Plazo, un instrumento de gestión reconocido ante el Acuerdo de París, que define los lineamientos generales de largo plazo que seguirá el país de manera transversal e integrada en la materia.

Se establece en la Ley Marco, además y de manera explícita, que varios de los aspectos fundamentales comprendidos por dicho instrumento, serán conformes a la Contribución Determinada a Nivel Nacional, tales como el Presupuesto nacional de emisiones de gases de efecto invernadero al año 2030 y 2050 y los objetivos, metas e indicadores de mitigación y adaptación a mediano plazo.

Así, la NDC se transforma en un instrumento vinculante, que cobra un rol de vital importancia en la acción climática nacional y que, como se evidenciará en lo sucesivo, trasciende el conflicto en específico del cambio climático, obedeciendo a la ratificación adoptada por Chile en el Acuerdo de París, en que se enfatiza la relación intrínseca que las acciones climáticas, sus respuestas e impactos tienen sobre el acceso equitativo al desarrollo sostenible y la erradicación de la pobreza. La NDC Chilena se estructura, entonces, intentando maximizar las sinergias entre los compromisos climáticos y la Agenda 2030 para el Desarrollo Sostenible y los Objetivos de Desarrollo Sostenible (ODS).

En materia de mitigación, el Acuerdo de París establece el siguiente objetivo de largo plazo: Mantener el aumento de la temperatura media mundial muy por debajo de 2 °C, con respecto a los niveles preindustriales, y proseguir los esfuerzos para limitar ese aumento de la temperatura a 1,5 °C [10].

Para responder a este objetivo, el Acuerdo, en su artículo 4.1, solicita a las Partes alcanzar un punto máximo o peak de emisiones mundiales de gases de efecto invernadero (GEI) lo antes posible y lograr un equilibrio entre emisiones y capturas después del año 2050 [10].

En esta línea, Chile se ha comprometido por medio de su NDC, a buscar una trayectoria que le permita alcanzar la neutralidad de GEI al año 2050 y, así mismo, lo ha ratificado en su Ley Marco del Cambio Climático.

El compromiso de mitigación contempla un presupuesto de emisiones de GEI que no superará las 1.100[MtCO₂eq], entre el 2020 y 2030, con un máximo de emisiones de GEI al 2025 y pretende alcanzar un nivel de emisiones de GEI de 95[MtCO₂eq] al 2030 [9].

Este compromiso, en palabras del mismo documento, es una visión y meta del país no sólo desde el punto de vista climático, sino que tiene implicancias económicas, sociales y ambientales [9], reforzando una mirada holística del problema.

En esa misma línea, se puntualiza que serán dos las vías de acción de cara al objetivo. Por un lado, es necesaria una disminución sostenida de las emisiones de GEI mediante un esfuerzo multisectorial del país, mientras que por otro, es esencial el aumento, mantención y protección de los actuales sumideros naturales de carbono, entre los cuales se encuentran las turberas: el objeto de estudio del presente Trabajo de Título.

Se presentan de igual manera en la NDC, contribuciones en lo que es definido como una Componente de integración. Ella la componen contribuciones que responden a un enfoque integrado de estrategias de mitigación y adaptación. Entendidas ambas estrategias como complementarias en la lucha por la gestión y reducción de los riesgos asociados al cambio climático.

Sobre esta Componente de integración, se estipulan diversas contribuciones que son englobadas en cuatro tópicos: Economía circular, Transversal a ecosistemas, Uso de la tierra, cambio de uso de la tierra y silvicultura (UTCUTS) y Océano.

En todas ellas, permea el entendimiento de la naturaleza como un ente fundamental, indivisible del desarrollo humano y de la protección y mantención de los ecosistemas naturales como una componente esencial para el bienestar de la sociedad, el desarrollo económico y, en particular, para la mitigación y adaptación al cambio climático.

En el apartado Transversal a ecosistemas, se menciona la formulación del Plan nacional de restauración de paisajes, entendido como un proceso continuo de mejoramiento del bienestar humano y recuperación de la funcionalidad ecológica de paisajes de gran extensión y diversidad de usos, actores y ecosistemas, tanto terrestres como de aguas continentales y marino-costeros [9]. Estos procesos de restauración, según el mismo documento, conducen hacia una mayor sustentabilidad y resiliencia del territorio frente al cambio climático, recuperando biodiversidad y aumentando la provisión de bienes y servicios ecosistémicos [9].

En el apartado de Uso de la tierra, cambio de uso de la tierra y silvicultura (UTCUTS), se puntualizan contribuciones a su vez englobadas en dos tópicos: Bosques y turberas.

La capacidad de captura de carbono de los ecosistemas terrestres cumple un rol de primer orden en la contención del aumento de la temperatura media del planeta. Cabe recalcar que esta Componente de integración está entonces íntimamente relacionada con los compromisos en materia de mitigación y es, en realidad, parte de una de sus dos vías de acción imprescindibles.

Los bosques son reconocidos no solo por sus capacidades de captura y almacenamiento de carbono (evidentemente alineada con las contribuciones de mitigación), sino también sus servicios ecosistémicos ligados a los ejes transversales de la NDC en materia de adaptación (seguridad hídrica, reducción de riesgos de desastres, inclusión de grupos vulnerables y solu-

ciones basadas en naturaleza). Además, se los reconoce como prestadores de un servicio de gran importancia en la preservación de la biodiversidad, la cual se ve altamente amenazada por los efectos del cambio climático. Se puntualiza, además, que un aumento de ecosistemas boscosos tiene una relación directa con el bienestar de las personas (salud, identidad, espiritualidad, equilibrio emocional), así como también, trae consigo beneficios culturales y de turismo [9].

Por su parte, las turberas son igualmente reconocidas por su capacidad de secuestro y almacenamiento de carbono, por su importancia en la preservación de la biodiversidad, por sus servicios ecosistémicos de filtrado, mantención de la calidad del agua, regulación del flujo del agua, reducción de ocurrencia de inundaciones y regulación de las temperaturas en áreas aledañas, todos ellos ligados a la adaptación al cambio climático.

Se las reconoce, además, como ecosistemas altamente amenazados por el cambio de uso de suelo, la explotación no sustentable, la expansión urbana y su infraestructura y los efectos del cambio climático, lo que pone en riesgo su sustentabilidad a largo plazo [9].

Sobre esta última temática, de especial interés para el presente Trabajo de Título, se enuncian las siguientes contribuciones:

- Al 2025, se habrán identificado las áreas de turberas, así como otros tipos de humedales, a través de un inventario nacional [9].
- Al 2030, se habrán desarrollado métricas estandarizadas para la evaluación de la capacidad de adaptación o mitigación al cambio climático de humedales, especialmente turberas, implementando acciones para potenciar estos co-beneficios, en cinco sitios pilotos en áreas protegidas públicas o privadas del país [9].

Como se puede intuir, el Trabajo de Título está en profunda concordancia con la NDC nacional desde su génesis hasta, en específico, estas últimas dos contribuciones enunciadas.

2.1.2.2. Ley de Protección de Turberas

Nuestro ordenamiento jurídico distingue entre sustancias minerales y sustancias superficiales, haciendo aplicable un régimen jurídico distinto según se trate de una sustancia o de otra [11].

Mientras las sustancias superficiales son propiedad del dueño del terreno y, por tanto, están sujetas al régimen de propiedad privada, las sustancias minerales son objeto de dominio absoluto y exclusivo del Estado, no susceptibles de propiedad privada y corresponde al Estado otorgar concesiones para su uso y goce [11].

Según la doctrina y jurisprudencia, las arcillas superficiales son aquellas que se encuentran en el suelo agrícola, en el suelo cultivable o en la sobrecarga vegetal, mientras que las sustancias minerales son aquellas sustancias que se encuentran por debajo de la sobrecarga vegetal. Desde este punto de vista, el ecosistema de las turberas ha estado sujeto a dos regímenes distintos según sus componentes; mientras las plantas hidrófilas (tales como el musgo *Sphagnum*

magellanicum) están sujetas a la legislación específica que regula el uso y aprovechamiento del recurso natural suelo y en particular su uso agrícola, la turba está sujeta a la legislación minera siendo una sustancia mineral concesible [11].

En virtud de lo anterior, la explotación de la turba es permitida en conformidad a lo dispuesto en el Código de Minería. No obstante, los proyectos que contemplen su extracción requerirán ingresar al Sistema de Evaluación de Impacto Ambiental [11].

La extracción de turba es una actividad realizada por particulares que operan bajo concesión minera y que impacta en mayor medida la ecología e hidrología del lugar. Las turberas son drenadas para luego extraer con mayor facilidad la turba, en esta última labor, se utilizan retroexcavadoras que eliminan por completo la cubierta vegetal, afectando directamente a la biodiversidad. Estas acciones dificultan en extremo la regeneración de la turbera, dejando el sustrato mineral expuesto en superficie [11].

Las obras de drenaje que se construyen alrededor de las turberas que son explotadas, si bien facilitan la labor de extracción, provocan un gran daño a la hidrología del lugar, muchas veces irreversible, afectando la cantidad y calidad de las aguas subterráneas y superficiales [11].

De acuerdo a la Ley N° 19.300, y al Reglamento del Sistema de Evaluación de Impacto Ambiental: “deben someterse a dicho sistema los proyectos o actividades de drenaje o desecación de cuerpos naturales de aguas tales como lagos, lagunas, pantanos, marismas, turberas, vegas, albuferas, humedales o bofedales, exceptuándose los identificados en los incisos anteriores, cuya superficie de terreno a recuperar y/o afectar sea superior a diez hectáreas, tratándose de las regiones V a VII, incluida la Metropolitana; o a treinta hectáreas, tratándose de las regiones VIII a XII” [11].

Lo anterior determina que bien pueden existir proyectos que contemplen la extracción de turba que dada su menor dimensión ingrese al Sistema de Evaluación de Impacto Ambiental a través de una Declaración y no de un Estudio de Impacto Ambiental, que implicaría contar con planes de mitigación, reparación y compensación de los proyectos, además de un plan de seguimiento de las variables ambientales relevantes del mismo [11].

El 14 de agosto de 2018, se ingresó un proyecto de ley que tiene por objeto preservar y conservar las turberas, como reservas estratégicas para la regulación de la química atmosférica y de la hidrología, para la protección de la biodiversidad y para el turismo sustentable [11].

Este pretende, entre otras iniciativas, incorporar en la Ley N° 19.300 sobre Bases Generales del Medio Ambiente, un inciso tercero nuevo del siguiente tenor:

- En todo caso, los proyectos o actividades que contemplen la extracción de turba y/o de los vegetales que se encuentran en su superficie, dentro de los cuales se incluye, entre otros, al musgo sphangum, y con los que se conecta funcionalmente, requerirán la elaboración de un Estudio de Impacto Ambiental [11].

De esta manera, se busca establecer que todo proyecto que contemple la extracción de tur-

ba o de las plantas hidrófilas que forman parte de las turberas, necesariamente debe ingresar al Sistema de Evaluación de Impacto Ambiental mediante un Estudio de Impacto Ambiental [11].

A la fecha de 19 de diciembre del 2022, el proyecto aún se encuentra en tramitación.

2.1.3. Caracterización del objeto de estudio

En la presente sección, se pretende caracterizar de manera general el objeto de estudio del Trabajo de Título: las turberas.

Las turberas son grandes extensiones de humedales que en su definición más simple, son ambientes terrestres en los cuales la producción primaria neta excede la descomposición de la materia orgánica[1].

Lo anterior se observa debido a una serie de condiciones y restricciones propias de estos ambientes, que se relacionan con el proceso de descomposición, por ejemplo: anegamiento constante, acidez, anoxia (falta de oxígeno), baja disponibilidad de nutrientes, bajas temperaturas y a los sustratos que son relativamente poco lábiles[12]. El depósito producido por el fenómeno relatado, es rico en materia orgánica parcialmente descompuesta y se denomina turba.

Este ecosistema se encuentra usualmente en lugares donde la precipitación es alta (entre 800 y 6000 mm de precipitación anual) y la evaporación es baja; en áreas donde nunca o rara vez hay sequías de verano; en áreas frías (por ejemplo, boreales y subantárticas) y húmedas (oceánicas y tropicales húmedas). Se caracterizan, además, por presentar un nivel freático muy cercano a la superficie del suelo, con leves fluctuaciones estacionales. En Chile, se encuentran desde la Región de la Araucanía hasta la Región de Magallanes [1].

La formación de las turberas ha sido explicada mediante dos procesos principalmente: la terrestrización y la plaudificación, cuyos esquemas se pueden observar en la Figura 2.7.




Figura 2.7: Proceso de terrestrización (a) y plaudificación (b). Tomada de [1].

En el primero de ellos, la formación deriva del relleno progresivo de un cuerpo de agua como un lago o una laguna, donde la vegetación va invadiendo desde los márgenes y sus restos se van acumulando en el lugar. En el segundo, la turba se acumula sobre una superficie mineral, plana o ligeramente convexa, pero sin una concavidad bien definida. En estos sitios, la elevada pluviosidad y la saturación del sustrato son los responsables de las limitaciones

a la degradación de los restos vegetales que favorecen su acumulación para la formación de turba [13].

En Chile, la distribución geográfica de las turberas al sur del territorio se relaciona con la historia glacial de la zona. Desde el último máximo glacial, el retroceso de los cuerpos de hielo fue dejando grandes masas de agua y formando numerosos humedales y lagunas someras, que con el paso del tiempo fueron colonizadas por las comunidades vegetales que se observan en la actualidad, con especies como el musgo *Sphagnum* y otras briófitas, importantes pioneras colonizadoras de zonas con drenaje pobre y márgenes de lagos. Así, gran parte de las turberas de la Patagonia se estima que iniciaron su formación entre los 17.000 y 13.500 años AP (años calendario) [14].

Como se puede observar en la Figura 2.8, la estructura de una turbera se divide en dos. El acrotelmo es la capa superficial biológicamente activa de una turbera. Va desde la superficie hasta una profundidad determinada por el nivel freático (usualmente entre 0,3 y 0,5 m de profundidad) [1]. Esta capa está dominada por plantas hidrófilas con una gran capacidad para retener agua, especialmente musgos del género *Sphagnum*. Es una zona aeróbica, con alta conductividad hidráulica y en ella tienen lugar procesos como la fijación de carbono y la descomposición de la materia orgánica [1]. Por su parte, el catotelmo corresponde a la sección de materia orgánica ubicada inmediatamente bajo el acrotelmo, desde el nivel freático y hasta el suelo mineral [1]. La materia orgánica que pasa desde el acrotelmo al catotelmo, se acumula en esta última capa en un estado de descomposición incompleta (a una tasa menor a 1 mm/año [15]) y, en el largo plazo, genera la capa de turba característica de estos ecosistemas, que puede alcanzar varios metros de profundidad [1].

La importancia de la protección de las turberas radica en la amplia variedad de servicios ecosistémicos que ellas cumplen. Albergan una amplia y única biodiversidad, por lo que son claves en la conservación de la misma. Son, además, importantes archivos paleoambientales para reconstruir los cambios paisajísticos y climáticos del pasado [1]. Son parte activa del ciclo hidrológico, siendo recargadas por precipitaciones y liberando gradualmente el agua hacia las cuencas [1], además de operar como filtro natural hacia las aguas subterráneas, reduciendo la movilización y transporte de sedimentos y fijando compuestos nocivos como metales pesados [13].




Figura 2.8: Estructura de una turbera. Tomada de [1].

Por si fuera poco, son el reservorio de carbono más eficiente entre los ecosistemas terrestres: con sólo el 3% del total de la superficie terrestre del planeta, contienen tanto carbono como toda la biomasa del resto de ecosistemas terrestres y casi la misma cantidad del carbono que se encuentra en la atmósfera. Así, las turberas son uno de los principales reguladores del

clima a nivel global [1].

Este gran reservorio natural de carbono en la Tierra, se ve hoy altamente amenazado tanto por las condiciones de cambio climático, como por su explotación para extracción de turba u otros fines. La razón de lo anterior radica en que la exposición de la turba (producto del drenaje del ecosistema) al contacto con el aire, provoca su oxidación y descomposición, liberando dióxido de carbono a la atmósfera y contribuyendo al cambio climático [16].

Según [2], las turberas están bajo una amenaza significativa a nivel mundial debido al drenaje, los incendios, el pastoreo excesivo y otros impactos humanos. Más de $650000[km^2]$ de turberas han sido afectadas por la actividad humana y las turberas drenadas o quemadas contribuyen con alrededor de dos mil millones de toneladas de emisiones de dióxido de carbono por año, aproximadamente el 5% de todas las emisiones antropogénicas.

2.1.4. Teoría Polarimétrica

2.1.4.1. Fundamentos

Las radiación electromagnética se propaga por medio de ondas. Estas pueden ser descritas según su amplitud, fase y polarización.

En la Figura 2.9 se puede observar, por ejemplo, una onda electromagnética propagándose a lo largo del eje z . La polarización se puede describir como la forma trazada por la punta del vector de campo eléctrico, proyectada sobre el plano perpendicular al desplazamiento (en este caso el plano X-Y).




Figura 2.9: Esquema de propagación de una onda electromagnética. Tomada de [17].

El vector de campo eléctrico puede oscilar, en realidad, en cualquier dirección del plano perpendicular al desplazamiento, describiendo así diversas formas de polarización.

A modo de ejemplo, en la Figura 2.10 se observan ondas con polarización lineal vertical, lineal horizontal y no polarizada.




Figura 2.10: Ejemplo de polarización. Tomada de [17].

Estas son, quizás, las polarizaciones más simples e intuitivas, sin embargo, mediante dos componentes de campo eléctrico perpendiculares, cualquiera estas sean (y en particular, por supuesto, una componente horizontal y una vertical) se puede transmitir cualquier forma de onda.

La polarimetría es la ciencia de adquirir, procesar y analizar el estado de polarización de un campo electromagnético. Para el caso de polarimetría de radar transportados en satélites, el procedimiento de adquisición de datos puede ser simplificado en tres etapas: en una primera etapa, se emite una onda completamente polarizada (con polarización lineal vertical y/o horizontal) desde el satélite; luego, esta onda interactúa con el objetivo en la Tierra; posteriormente, se recibe una onda retrodispersada nuevamente en el satélite.

Se dice que el objetivo es coherente si es que la onda retrodispersada es polarizada, o incoherente en caso contrario.

El proceso de transmisión y recepción de una onda no tiene por qué ser dentro de una misma polarización. Al proceso de transmitir y recibir datos en una misma polarización, se lo denomina Co-polarización y se representa con las letras VV (transmisión vertical y recepción vertical) o HH (transmisión horizontal y recepción horizontal). Por su parte, el proceso de transmitir y recibir datos en una misma polarización, es denominado Polarización cruzada y se representa con las letras VH (transmisión vertical y recepción horizontal) o HV (transmisión horizontal y recepción vertical).

Existen diversos grados de completitud en la adquisición de datos polarimétricos. Para efectos de este trabajo, se utilizan datos Cuádruples o Totalmente polarimétricos, que registran para cada medición, las amplitudes y diferencias de fase de cada uno de los cuatro modos anteriormente descritos (VV, HH, VH y HV).

En este tipo de adquisición, se define la matriz de dispersión como aquella que describe la transformación de la onda incidente en la onda retrodispersada. Esta matriz contiene entonces, información valiosa sobre la naturaleza del objetivo con que interactúa y es el principal insumo con que se cuenta para su estudio.

$$\begin{bmatrix} E_h^s \\ E_v^s \end{bmatrix} = \begin{bmatrix} S_{hh} & S_{hv} \\ S_{vh} & S_{vv} \end{bmatrix} \begin{bmatrix} E_h^i \\ E_v^i \end{bmatrix} \quad (2.1)$$

En la ecuación 2.1, tomada de [17], el índice i corresponde a la onda incidente, el índice s , a la onda dispersada, v a vertical y h a horizontal.

Con los elementos de la matriz de dispersión, se construyen los denominados vectores objetivo k , en base lineal y base Pauli, respectivamente.

$$k = \begin{bmatrix} S_{xx} & S_{xy} & S_{yx} & S_{yy} \end{bmatrix}^T \quad (2.2)$$

$$k_p = \frac{1}{\sqrt{2}} \begin{bmatrix} S_{xx} + S_{yy} & S_{xx} - S_{yy} & S_{xy} + S_{yx} & i(S_{xy} - S_{yx}) \end{bmatrix}^T \quad (2.3)$$

En base a estos dos vectores objetivo k (tomados de [18]), se construyen matrices descriptoras de segundo orden, denominadas Matriz de Coherencia $[T] = k_p \cdot k_p^{*T}$ y Matriz de Covarianza $[C] = k \cdot k^{*T}$ [18].

2.1.4.2. Geometría

Para el caso de SAR (radar de apertura sintética) polarimétrico transportado en satélites, resulta interesante describir someramente la geometría del problema, principalmente para reconocer parámetros que serán mencionados en lo sucesivo.

El radar barre el terreno con pulsos de energía colectando datos con una visión lateral [19], como se puede observar en la Figura 2.11.

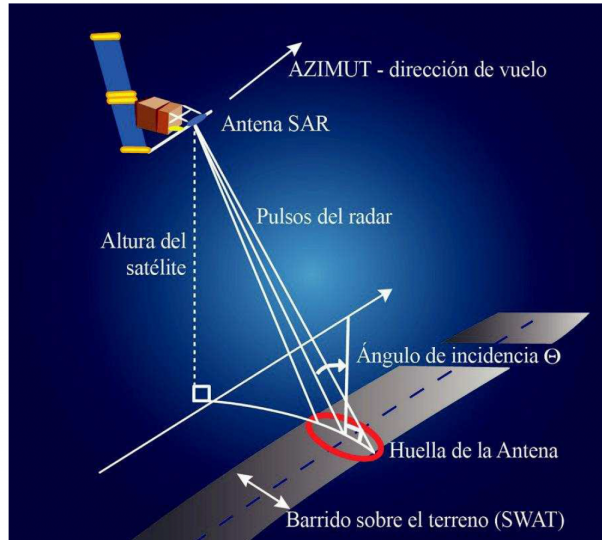


Figura 2.11: Geometría SAR polarimétrico satelital. Tomada de [19].

Se consideran los retardos entre la recepción de fracciones del pulso de la señal más alejada de la antena y de las más próximas y se convierten en distancias [19], para determinar el ancho de barrido. El ángulo de incidencia cambia en la dirección de alcance (a lo largo del barrido), por lo que la geometría de visualización es diferente punto a punto [19]. Este ángulo influye en la brillantez de la imagen generada.

La resolución espacial en la dirección de alcance depende de la longitud de onda del pulso transmitido y del ancho de banda del sistema en el canal del alcance [19]. En la dirección de vuelo, la resolución espacial depende del largo de la antena sintética, inversamente proporcional al tamaño de la antena real. Así, los SAR logran una resolución espacial fina en la dirección de vuelo [19].

2.1.4.3. Moteado

El moteado es un fenómeno que se evidencia en la construcción de productos polarimétricos. Este fenómeno tiene su origen en el uso de una única longitud de onda para la transmisión de pulsos hacia el objetivo.

El resultado de lo anterior, es la interferencia entre los pulsos. En algunas zonas (o píxeles) esta interferencia es constructiva, aumentando la brillantez de la imagen mientras que en otras, es destructiva, disminuyendo la misma.

Existen diversos mecanismos para apaciguar los efectos del moteado, como filtros a aplicar sobre una única imagen, o promedios realizados entre imágenes de períodos de tiempo consecutivos. En el desarrollo del presente trabajo, se puntualiza brevemente sobre algunos de ellos.

2.1.4.4. Teoremas de descomposición

Los teoremas de descomposición son métodos para la interpretación de los datos obtenidos en las matrices de coherencia o covarianza. Permiten asociar la respuesta del objetivo en

términos de su retrodispersión, a sus matrices descriptoras.

A continuación, se revisan dos teoremas de descomposición utilizados típicamente en análisis polarimétricos, que serán utilizados en el presente trabajo.

2.1.4.5. Descomposición de Cloude y Pottier

En ella, se descompone la matriz de coherencia en sus valores y vectores propios como se muestra en la ecuación 2.4 (tomado de [20]).

$$[T] = [U_3] \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} [U_3]^{-1} \quad (2.4)$$

Donde, U_3 es una matriz que contiene los tres vectores propios de T [20].

$$[U_3] = [u_1 \quad u_2 \quad u_3] \quad (2.5)$$

Por su parte, cada vector propio puede ser parametrizado según:

$$u_i = [\cos \alpha_i e^{i\phi_i} \quad \sin \alpha_i \cos \beta_i e^{i(\phi_i + \delta_i)} \quad \sin \alpha_i \sin \beta_i e^{i(\phi_i + \gamma_i)}]^T \quad (2.6)$$

La forma diagonal de la matriz de coherencia, descrita previamente, puede ser considerada como un conjunto de vectores objetivo estadísticamente independientes [20], como se muestra en la ecuación 2.7.

$$[T] = \sum_{i=1}^3 \lambda_i T_i = \sum_{i=1}^3 \lambda_i u_i u_i^{*T} \quad (2.7)$$

Cloude fue el primero en considerar una descomposición basada en los vectores propios [21]. En una primera instancia, se desarrolló un algoritmo que permitiese obtener el mayor valor propio. Así, según [20], la matriz de coherencia asociada se puede describir como sigue:

$$T_1 = \lambda_1 u_1 u_1^{*T} \quad (2.8)$$

Siendo λ_1 el mayor valor propio de la matriz de coherencia. Se define entonces, según [21], que:

$$T_1 = \lambda_1 u_1 u_1^{*T} = k_1 k_1^{*T} \quad (2.9)$$

Y que el valor de k_1 es:

$$k_1 = e^{j\phi} \begin{bmatrix} \sqrt{2A_0} \\ \sqrt{B_0 + B e^{j \arctan \frac{D}{C}}} \\ \sqrt{B_0 - B e^{j \arctan \frac{G}{H}}} \end{bmatrix} \quad (2.10)$$

Se definen en base a esto, tres métricas descriptoras del vector objetivo y, por ende, valga la redundancia, del objetivo en el cual se produce la retrodispersión:

- **Superficie:**

En [21], la métrica Superficie se define como:

$$Superficie = A_0 \quad (2.11)$$

Según [21], cuando $A_0 \gg B_0 + B, B_0 - B$, se trata de una retrodispersión por superficie.

- **Doble rebote:**

Por su parte, en [21], se define la métrica Doble Rebote como:

$$DobleRebote = B_0 + B \quad (2.12)$$

Según [21], cuando $B_0 + B \gg A_0, B_0 - B$, se trata de una retrodispersión por doble rebote.

- **Volumen:**

Finalmente, en [21], la métrica Volumen, es descrita como:

$$Volumen = B_0 - B \quad (2.13)$$

Según [21], cuando $B_0 - B \gg A_0, B_0 + B$, se trata de una retrodispersión por volumen.

Luego, en base a esta misma descomposición, se generan otras tres métricas descriptoras que incorporan, esta vez, no solo el valor propio más grande, sino que a todos.

- **Entropía:**

Describe el grado de aleatoriedad del mecanismo dispersor ($H = 0$ indica un mecanismo puro, $H = 1$ indica retrodispersión aleatoria). Las ecuaciones 2.14 y 2.15 son tomadas de [18].

$$H = \sum_{i=1}^n -P_i \log_n P_i \quad (2.14)$$

$$P_i = \frac{\lambda_i}{\sum_{j=1}^n \lambda_j} \quad (2.15)$$

- **Anisotropía:**

Describe la importancia relativa entre los segundos y terceros mecanismos de dispersión. La ecuación 2.16 es tomada de [22].

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (2.16)$$

- **Ángulo alpha medio:**

Indica el tipo de dispersión. Superficial (0°), por volumen (45°) o por rebote (90°). La ecuación 2.17 es tomada de [22].

$$\alpha = \sum_{i=1}^3 P_i \alpha_i \quad (2.17)$$

2.1.4.6. Descomposición de Touzi

Esta descomposición nace de la constatación de una ambigüedad en la descomposición de Cloude: algunos de los parámetros utilizados para caracterizar el objetivo dependen del ángulo de orientación. Se produce entonces un sesgo.

Touzi recoge un modelo previo denominado Con-diagonalización de Kennaugh-Huynen, que explora otro procedimiento de diagonalización, diferente al presentado previamente.

Sin entrar en demasiado detalle, la descomposición de Touzi propone un nuevo modelo de vector retrodispersado de cinco parámetros independientes, como se puede observar en la ecuación 2.18 (tomada de [23]).

$$e_T^{\vec{S}V} = m |e_T^{\vec{e}}|_m e^{j\phi_s} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos 2\psi & -\sin 2\psi \\ 0 & \sin 2\psi & \cos 2\psi \end{bmatrix} \begin{bmatrix} \cos \alpha_s \cos 2\tau_m \\ \sin \alpha_s e^{j\phi_{\alpha_s}} \\ -j \cos \alpha_s \sin 2\tau_m \end{bmatrix} \quad (2.18)$$

Donde, según [23], el parámetro $|e_T^{\vec{e}}|_m$ obedece a la descomposición mostrada en la ecuación 2.19.

$$[T] = \sum_{i=1}^3 \lambda_i [T]_i \quad (2.19)$$

La matriz $[T]$ se computa en una ventana móvil (por ejemplo de 60 muestras independientes), se diagonaliza y se aplica sobre ella el modelo de vector retrodisperso para cada una de las parametrizaciones de tres vectores propios [23]. Finalmente, para cada valor propio, se describe el conjunto de parámetros del modelo, como se muestra en la ecuación 2.20 [23].

$$ICTD_i = (\lambda_i, m_i, \psi_i, \tau_{m_i}, \alpha_{s_i}, \phi_{\alpha_{s_i}}) \quad (2.20)$$

El parámetro $\phi_{\alpha_{s_i}}$, denominado Phi para efectos del presente Trabajo de Título, es utilizado como métrica descriptora de la retrodispersión en el objetivo.

2.2. Estado del Arte

2.2.1. Mapeo del ecosistema en el territorio nacional.

Variados han sido los esfuerzos cartográficos por describir las turberas de la Región de Magallanes.

La evolución cartográfica tiene sus inicios en el año 1917, con la publicación Tierra el Fuego y sus turberas, por Guido Bonarelli. Ahí se describen principalmente las características, origen, vegetación, condiciones de formación y diferentes tipos de turberas, desde la observación in situ [1].

Los esfuerzos por la identificación, caracterización y mapeo de la zona no cesaron en los años venideros y, en 2005, se incorporó por primera vez el uso de imágenes satelitales dentro de una investigación relativa al tema. Se trató del proyecto Catastro y Caracterización de los turbales de Magallanes, por Ruiz y Doberti [24].

En este trabajo, se planteó identificar y zonificar técnicamente los turbales (concepto que se adopta de manera genérica). Además de otros ejes que desarrollan como, por ejemplo: composición botánica, estados de conservación, análisis físico- químico, aspectos relacionados con el uso y manejo, análisis proximal de mercado de la turba a nivel internacional, nacional y regional y análisis de fortalezas, oportunidades, debilidad y amenazas (FODA), como una primera visión en la evaluación estratégica del recurso [24].

El estudio se realizó sobre 26 localidades y si bien ya se trata de cartografías elaboradas, que albergan mayor cantidad de datos y presentan una estandarización en sus elementos formales, aparecen dificultades de legibilidad en los mapas. No se especifica en el informe el método particular ni los criterios para establecer las unidades cartográficas homogéneas [1] y se presentan, además, discrepancias conceptuales en cuanto a la clasificación de turberas desarrolladas en [1].

El año 2013 se publicó una propuesta actualizada del estudio que, según [1], sigue siendo confusa. Cabe mencionar que el ejercicio de teledetección aplicada a estudios de identificación, reconocimiento y clasificación, se realiza sólo en la Península de Brunswick [1].

En [1], se realiza una corrección vectorial a la base digital realizada por el Catastro y Caracterización de los turbales de Magallanes, por Ruiz y Doberti [24]. Sobre ella se puntualiza:

- El área de estudio cubre una extensa superficie, esto significa perder calidad en el detalle y se pierda la visibilidad de espacios más pequeños [1].
- El levantamiento de los datos generados a partir de información geográfica parcial en términos espaciales y cartográficos presentados anteriormente, ha permitido generar importantes insumos, pero son insuficientes en relación a la envergadura del extenso territorio regional [1].
- Estos residuos generan errores o áreas incorrectas que no corresponden al área de estudio y en el proceso de construcción y cálculo de área podrían ser sumadas aumentando la cantidad de superficie [1].

- Hay alta presencia de nubes que restringe áreas, dificulta la discriminación, fotointerpretación y la reedición de las turberas de manera certera [1].

2.2.2. Descomposición de Touzi para el mapeo de turberas.

El modelo de la descomposición de Touzi ha sido investigado para la clasificación de humedales, entregando buenos resultados.

En la Figura 2.12 se observan cuatro fotos aéreas en conjunto con datos de campo, obtenidas utilizando datos polariméricos de rada de apertura sintética Convair-580, recopilados en el sitio de humedales Ramsar, Mer Blue, ubicado al este de Ottawa, Ontario, Canadá [23].

La primera de ellas es construida con una mezcla de las intensidades HH, HV y VV en los canales RGB, mientras que las otras tres representan, cada una de ellas, un parámetro de la descomposición de Touzi, obtenidos para la primera componente principal.




Fig. 10. Convair-580 multipolarization SAR image (Mer Bleu). (Red) HH. (Green) HV. (Blue) VV.




Fig. 12. Dominant scattering type magnitude.




Fig. 11. Dominant scattering type phase.

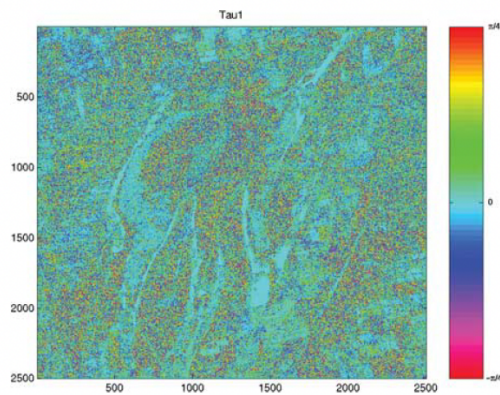


Fig. 13. Dominant scattering type helicity.

Figura 2.12: Parámetros de Touzi para humedal Mer Bleu. Tomada de [23].

Se observa que el parámetro de fase $\phi_{\alpha_{s_i}}$ entrega prácticamente de manera directa una clasificación no supervisada, mientras que el resto de los parámetros no entrega mayor información.

Si bien la implementación del mapeo en cuestión dista sustantivamente de la simple obtención de este parámetro, su cómputo es naturalmente incorporado a la hora de implementar los algoritmos de clasificación supervisada del presente Trabajo de Título.

2.3. Metodología

2.3.1. Enfoque

El trabajo realizado sigue un enfoque cuantitativo para el diseño e implementación de un clasificador inteligente, siguiendo la metodología ágil.

Esta consiste en el desarrollo de ciclos que comprenden el diseño, el desarrollo de código y pruebas, la implementación del trabajo, el análisis de resultados o comentarios y finalmente, las discusiones y planificación de cara a un nuevo ciclo. Posterior al cierre de cada iteración, se inicia nuevamente el ciclo, recogiendo las oportunidades de mejora previamente analizadas. En la Figura 2.13 se puede observar un esquema de lo relatado.




Figura 2.13: Esquema de metodología ágil.

2.3.2. Etapas de desarrollo

Este trabajo, corresponde a una primera etapa de desarrollo de un proyecto que en su totalidad consta de dos etapas fundamentales. Cada una de ellas, sigue la misma metodología ágil, de la naturaleza cíclica comentada en el apartado previo.

En la primera etapa, como ya se comentó anteriormente, se busca desarrollar y evaluar una herramienta de clasificación para un área de estudio en específico, que permita demostrar la factibilidad del mapeo de turberas en la zona, en base a los productos SAOCOM disponibles. Así, se espera justificar la solicitud de productos correspondientes a una mayor extensión de territorio, permitiendo reiniciar el ciclo de trabajo y habilitando una eventual segunda etapa de desarrollo.

A continuación, se detallará en extenso cada una de las fases (Diseño, Código y Pruebas, Implementación, Comentarios y Discusiones y planificación) que conforman la primera etapa de desarrollo del proyecto, correspondiente al presente Trabajo de Título.

2.4. Diseño

En esta fase, se busca encausar el desarrollo completo del ciclo de trabajo, que culmina con la materialización de la herramienta de clasificación. Para ello, por una parte, se definen, obtienen y describen, todos aquellos insumos que se utilizan en el trabajo realizado. Por otra y dependiente de la primera, se define cada uno de los hitos de desarrollo de las fases del ciclo.

2.4.1. Insumos

La presente sección, trata todo lo relativo a los insumos, o variables de entrada con las que se desarrolla el clasificador.

2.4.1.1. Productos SAOCOM

Los datos polarimétricos utilizados, corresponden a un producto SAOCOM, facilitado por la CONAE (Comisión Nacional de Actividades Espaciales), organismo del Gobierno de Argentina, responsable del Plan Nacional Espacial. Se trata de un único producto obtenido mediante un radar de apertura sintética (SAR), completamente polarimétrico (con polarización cuádruple), de banda L.

En la Tabla 2.1, se presentan algunas de las características técnicas más importantes de los productos SAOCOM.

En específico, el producto utilizado corresponde al modo de adquisición *Single Look Complex* (SLC): datos complejos en rango oblicuo, calibrados radiométricamente y que no presentan correcciones geométricas [25]. Su fecha de adquisición data del 11 de febrero del año 2021 y su ID se comenta a continuación:

- “S1A_OPER_SAR_EOSSP__CORE_L1A_OLF_20210211T233707”

En la Tabla 2.2, se presentan, adicionalmente, algunas características específicas del producto utilizado.

Algunas de las particularidades que hacen de este producto uno idóneo para los fines deseados son: primero, su naturaleza de polarimetría de radar; segundo, su polarización cuádruple y; tercero, su frecuencia central en banda L. A continuación se puntualiza sobre cada una de estas particularidades.

Sobre su naturaleza de polarimetría radar, es importante destacar que dicha tecnología, permite obtener registros de retrodispersión en la Tierra en cualquier momento del año, ya que no dependen de la iluminación solar y no se ven comprometidos por perturbaciones atmosféricas como nubes o humo [19], a diferencia de las imágenes satelitales ópticas. Esto lo convierte en un insumo profundamente valioso, tanto para este mapeo inicial, como a la hora de proyectar un sistema que abarque una mayor cobertura de territorio y, más aún, que sea sistemático en el tiempo.

En una fase inicial del proyecto, la CONAE facilita un solo producto, restringido a una zona específica, que engloba la ciudad de Ushuaia. Ushuaia, capital de la provincia argentina de

Tabla 2.1: Características técnicas SAOCOM [25].

Instrumento	SAR banda L polarimétrico
Frecuencia central	1, 275 [GHz]
Orientación de la observación	A derecha en forma de operación nominal (con capacidad de observar hacia la izquierda)
Resolución espacial	10 a 100 [m] (según el modo de adquisición)
Ancho de barrido	20 a 350 [km] (según el modo de adquisición)
Rango de ángulos de incidencia	20 a 50 ° (según el modo de adquisición)
Rango dinámico (coeficiente de retrodispersión radar)	−35 [dB] a 5 [dB]
Exactitud de posicionamiento geográfico (con compensación de efectos topográficos)	25 [m] (órbita precisa de 18 días) 70 [m] (órbita precisa de 48 horas) 90 [m] (órbita a bordo)
Exactitud radiométrica absoluta	0, 5 [dB]
Exactitud polarimétrica	0, 3 [dB]
Órbita	Heliosincrónica Altura 620 [km] Hora local nodo ascendente 6:12:15 am Revisita: 16 días (un solo satélite) 8 días (para la constelación)
Ciclo de repetición espacial	16 días para cada satélite 8 días para la constelación

Tierra del Fuego, se encuentra a una latitud cercana a los $54^{\circ}S$. Catalogada como la ciudad más austral del mundo, frecuente nubosidad buena parte del año, así como el resto de la Patagonia chileno argentina.

Vale la pena destacar, por último, que se trata de una zona de relevancia geopolítica, ya que comprende territorio tanto chileno como argentino, poniendo de manifiesto la colaboración que supone necesaria el desarrollo del presente trabajo.

Sobre su tipo de polarización, como ya se ha comentado con anterioridad, el producto obtenido posee polarización cuádruple, es decir, informa sobre la amplitud y fase, en cada uno de los modos de polarización del radar (VV, HH, VH y HV). Esto posibilita la obtención de las métricas que son computadas para el mapeo (en cada una de las descomposiciones en cuestión), tal y como se describe en el Marco Teórico.

Finalmente, sobre su frecuencia central, como se puede observar en la Tabla 2.1, se trata de un producto de banda L. Esto impacta directamente sobre la capacidad de penetración de la onda incidente.

En [26], se estudia el uso del parámetro ϕ_{α_s} de la descomposición de Touzi para la caracterización de humedales. En él, se detalla que dicho parámetro es sensible al movimiento de

Tabla 2.2: Características específicas del producto [25].

Modo de Haz		Stripmap Quap Pol
Posición del Haz		S1
Rango mínimo de ángulos de incidencia [°]	Rango cercano	17,6
	Rango lejano	19,6
Resolución espacial nominal (Productos L1A). Rango terrestre x Acimut [m x m]		10 ×6
Mínimo ancho de barrido (rango terrestre) [km]		21,9
Longitud nominal en Acimut [km]		74,1

aguas superficiales (10-20 [cm] de profundidad) en turberas minerotróficas, y que eso hace posible su separación de turberas ombrotólicas arbustivas [26]. Además, y gracias a la penetración, este permite discriminar entre turberas ombrotólicas arbustivas dominadas por coníferas, de bosques caducos en tierras altas, bajo condiciones frondosas [26].

Es interesante destacar, que estas conclusiones se obtienen utilizando un producto polarimétrico de banda C, de peor capacidad de penetración que el utilizado en el presente trabajo. Es más, se enuncia en [26], que los productos SAR de banda L, de una onda mucho más penetrante, deben proporcionar la información complementaria requerida para una mejor separación de los bosques de humedales de los bosques de tierras altas.

2.4.1.2. Modelo de elevación digital

De manera adicional, se incorpora como insumo un modelo de elevación digital. Se trata del modelo ALOS PALSAR, de 12,5[m] de resolución espacial, obtenido en noviembre del 2022.

2.4.1.3. Área de estudio

La extensión total (contando tanto datos válidos como sin información) alcanzada por el producto SAOCOM disponible, en coordenadas geográficas es la siguiente: $-68,6543216595861310, -55,0787239247091662$: $-68,0899781690408474, -54,6002713229189851$. Posee 8.811 píxeles de anchura y 7.470 de altura, de una resolución espacial de $6,404987975772188208e - 05, -6,404987975772188208e - 05$ grados (nuevamente en coordenadas geográficas).

El área de estudio seleccionada para el presente Trabajo de Título, corresponde a la porción de píxeles válidos de la extensión total recién descrita. En la Figura 2.14 se puede observar una imagen referencial del área que describen dichos píxeles. Vale la pena destacar que el polígono allí representado, es obtenido luego de un flujo de procesamiento realizado en el software SNAP, que será comentado en detalle más adelante.

En total, se dispone de 14.066.689 píxeles válidos, para cada uno de los cuales se cuenta con su matriz de coherencia. Dicha matriz, al ser simétrica, puede ser descrita por nueve variables: T11, T12 real, T12 imag, T13 real, T13 imag, T22, T23 real, T23 imag y T33, según 2.14 .

$$[T] = \begin{bmatrix} T11 & T12_{real} + T12_{imag} & T13_{real} + T13_{imag} \\ T12_{real} + T12_{imag} & T22 & T23_{real} + T23_{imag} \\ T13_{real} + T13_{imag} & T23_{real} + T23_{imag} & T33 \end{bmatrix} \quad (2.21)$$

Como ya se ha comentado en reiteradas ocasiones, se busca desarrollar la herramienta de clasificación en el área de estudio descrita, para justificar una solicitud de información relativa a una mayor cobertura de territorio en la Patagonia.

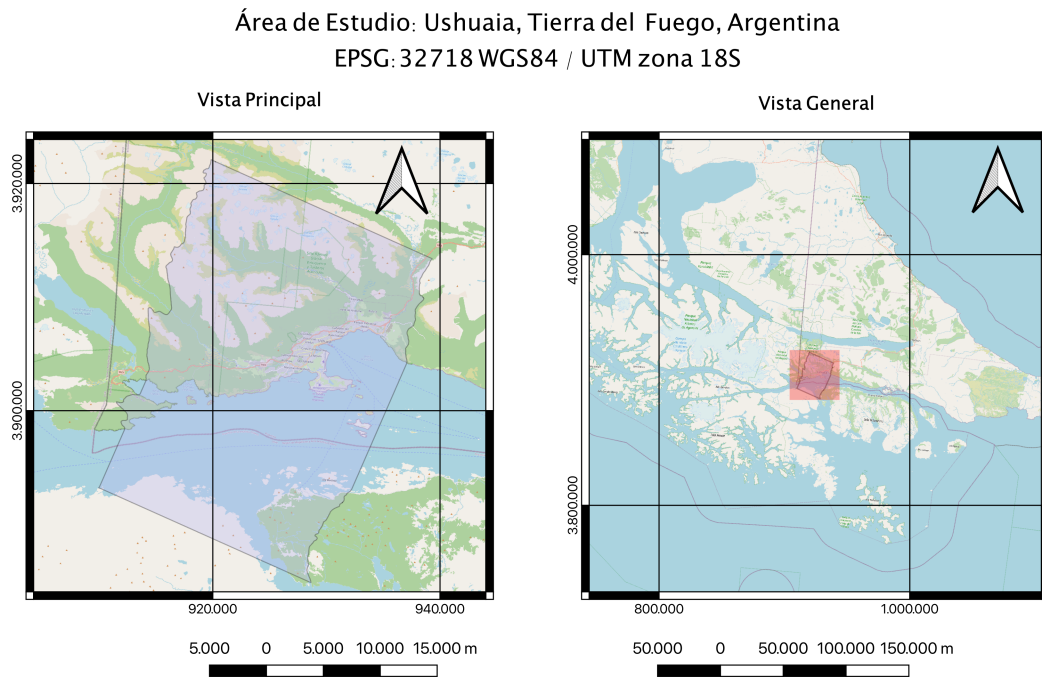


Figura 2.14: Área de estudio (Elaboración propia).

2.4.1.4. Definición de métricas

En base a los insumos seleccionados y según la revisión bibliográfica realizada, se definen diversas métricas a explorar de cara al objetivo de clasificación.

Del producto SAOCOM, se establece la obtención de métricas derivadas de la Descomposición de Cloude-Pottier y de la Descomposición de Touzi.

De la Descomposición de Cloude-Pottier, se explora la obtención de las siguientes métricas:

- Entropía

- Anisotropía
- Alfa
- Superficie
- Volumen
- Doble Rebote

La expresión matemática de cada una de ellas es descrita en la sección 2.1.4.5. Por su parte, de la Descomposición de Touzi, se explora la métrica Phi correspondiente al primer valor propio, descrita en la sección 2.1.4.6.

- Phi (o ϕ_{α_s} , como es denominado en [23])

Además, se agregan las siguientes métricas obtenidas directamente del modelo de elevación digital:

- Elevación
- Pendiente
- Orientación
- Sombreado

2.4.1.5. Definición de clases a identificar en el mapeo.

Habiendo ya establecido el área de estudio, se proceden a definir las clases que se identifican en ella y por ende, aquellas que son incorporadas en el clasificador. Como ya se comentó anteriormente, el mapeo debe permitir, al menos, la distinción entre tierras gestionadas y no gestionadas.

En base a un análisis visual de imágenes de alta resolución (utilizando el software Google Earth), el Doctor Alejandro Miranda Cerpa, Ingeniero en Recursos Naturales Renovables de la Universidad de Chile, identifica en el área tres clases, denominadas Turberas Sphagnum, Otras Turberas y Turberas Impactadas [27].

Como es de esperar, la clase Turberas Sphagnum hace referencia a polígonos donde se identifica claramente la presencia de dicho tipo de turberas. Por su parte, la clase Otras Turberas hace referencia a polígonos donde se sospecha la presencia de turberas, pero no se distingue claramente su tipología. Finalmente, la clase Turberas Impactadas hace referencia a polígonos donde se identifican turberas en las que se evidencia claramente el desarrollo de una actividad extractiva.

Las dos primeras clases, denominadas Turberas Sphagnum y Otras Turberas, se consideran de manera genérica como Tierras no gestionadas, mientras que la tercera, denominada Turberas Impactadas, cumple con la definición de Tierras gestionadas (aquellas en las que ha habido intervención humana y donde se han aplicado prácticas para la realización de actividades de producción, ecológicas o sociales [3]).

2.4.1.6. Polígonos de entrenamiento

Gracias al análisis ya mencionado, se obtienen polígonos georreferenciados de cada una de las clases en el área de estudio.

Se obtienen seis polígonos de la clase Turberas Sphagnum, cinco polígonos de la clase Otras Turberas y tres polígonos de la clase Turberas Impactadas en el área de estudio. En la Figura 2.15 se puede observar cada uno de los polígonos de entrenamiento utilizados (izquierda). A la derecha, se observa un acercamiento de la vista principal que permite visualizarlos de mejor manera. En ambas vistas, se utiliza la misma leyenda.

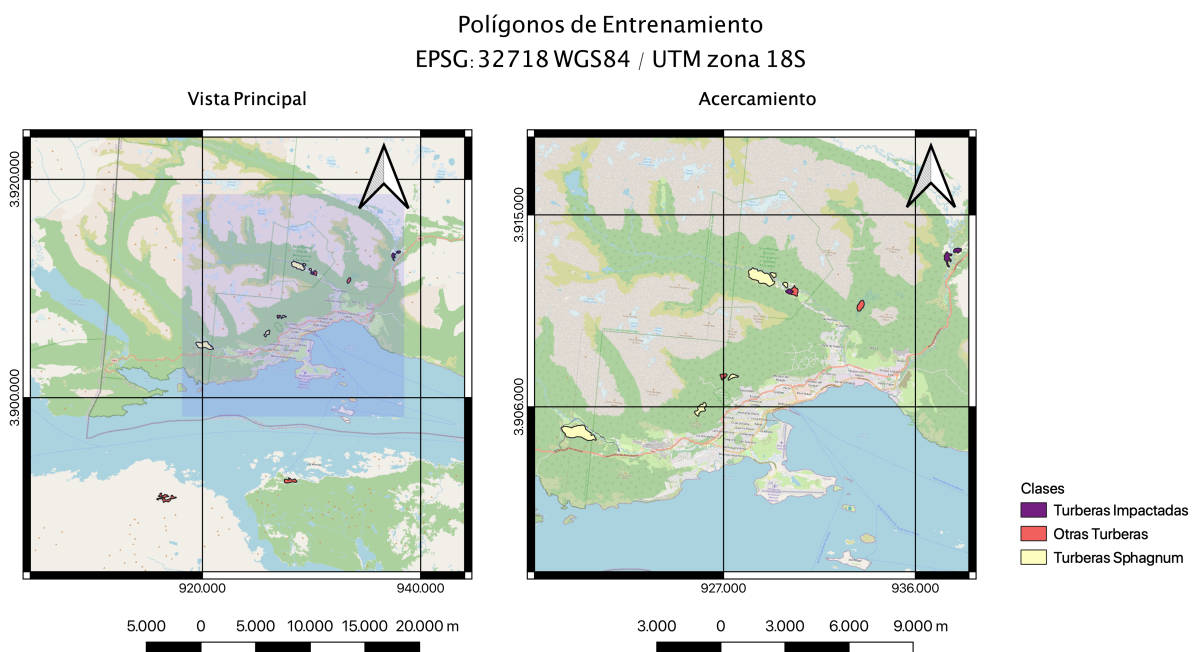


Figura 2.15: Polígonos de entrenamiento (Elaboración propia).

Con ello, culmina la sección de descripción de los insumos del clasificador y se procede a detallar el diseño de los hitos de cada una de las fases siguientes en el ciclo de trabajo.

2.4.2. Desglose de hitos de cada fase

A continuación, tal como el título indica, se precisa el desglose de cada una de las fases siguientes del ciclo de trabajo. El detalle de cada una de las fases se desarrolla en profundidad en la sección Resultados y Análisis.

Código y pruebas

Se establece que para el desarrollo de la fase Código y pruebas, se cumplen los siguientes hitos:

- Preprocesamiento descrito específicamente para el tipo de productos en cuestión. Desarrollo de un flujo de trabajo en el software de procesamiento SNAP y en un intérprete Python.
- Obtención de métricas para toda el área de estudio. Desarrollo en el software de procesamiento SNAP y en un intérprete Python.
- Exploración de métricas para cada polígono de entrenamiento disponible. Desarrollo en intérprete Python.
- Análisis de información generada y definición de métricas a incorporar en el algoritmo de clasificación a implementar.

Implementación del clasificador

Por su parte, para el desarrollo de la fase Implementación, se cumplen los siguientes hitos:

- Preprocesamiento.
- Generación de datos de entrenamiento y validación.
- Normalización de los datos.
- Definición y entrenamiento de algoritmos de clasificación supervisada a utilizar.
- Obtención y análisis de métricas de desempeño.
- Ampliación de la clasificación a toda el área de estudio.

Comentarios

Luego, para el desarrollo de la fase Comentarios, se cumplen los siguientes hitos:

- Discusión del preprocesamiento de los productos y la obtención de métricas.
- Discusión del entrenamiento de los clasificadores.
- Discusión de la generalización de los clasificadores.

Discusión y planificación

Finalmente, para el desarrollo de la fase Discusión y planificación, se cumplen los siguientes hitos:

- Evaluación de la aplicabilidad de la herramienta en instrumentos de gestión del cambio climático.
- Evaluación de la contribución en términos de protección.
- Evaluación de la factibilidad del uso de datos polarimétricos para el mapeo de turberas.
- Discusión orientada a la generalización del resultado a una mayor cobertura de territorio.

2.5. Resultados y Análisis

En la sección Resultados y Análisis de la presente memoria, se describe el trabajo realizado en las fases Código y pruebas e Implementación del clasificador. Como su nombre lo indica, en ella se intercalan los resultados obtenidos con breves análisis, organizados según los hitos que conforman las fases.

2.5.1. Fase Código y pruebas

En esta sección, se detallan los resultados obtenidos en cada hito de la fase Código y pruebas.

2.5.1.1. Preprocesamiento

Este hito dice relación con el preprocesamiento de los datos disponibles: tanto del producto SAOCOM, como del modelo de elevación digital.

El preprocesamiento de los datos completamente polarimétricos se realiza en el software SNAP. Inicialmente, se realiza una reflexión de la imagen obtenida, con el método *flip* incorporado en el software. Luego, por sobre el producto ya reflejado, se computa la matriz de coherencia del mismo, utilizando el método *Polarimetric Matrix Generator*, e indicando explícitamente que se requiere computar la matriz de coherencia del producto.

Esto se traduce en la obtención de las siguientes variables:

- T11
- T12 real
- T12 imag
- T13 real
- T13 imag
- T22
- T23 real
- T23 imag
- T13 imag
- T33

Que como ya se comentó y se muestra en la ecuación 2.14, permiten describir de manera absoluta la matriz de coherencia de cada uno de los píxeles del área de estudio. Se tiene entonces un archivo ráster de nueve bandas, una por cada elemento de la matriz.

Posteriormente, se aplica un filtro de moteado en cada una de las bandas de la matriz de coherencia obtenida. Esta etapa del preprocesamiento es esencial para poder, luego, evitar

dicho fenómeno en la visualización imágenes. En este caso, se utiliza el método *Single Product Speckle Filter* incorporado en el software SNAP, con sus parámetros por defecto, es decir, un filtro *Lee Sigma* (descrito en extenso en [28]) aplicado en una ventana de 7×7 .

Nuevamente, se obtiene un archivo ráster que contiene, en cada banda, la descripción del área de estudio en términos de un elemento de la matriz de coherencia, ahora, filtrado.

Por su parte, el preprocesamiento del modelo de elevación digital, comprende en primera instancia una reproyección del archivo georreferenciado. Inicialmente, el modelo se encuentra proyectado en coordenadas UTM 19S. Se reproyecta a coordenadas geográficas (EPSG:4326-WGS84) para coincidir con la proyección de los datos polarimétricos.

Posteriormente, se remuestra el archivo ráster reproyectado, para hacer coincidir su resolución espacial con aquella de los datos polarimétricos.

Y finalmente, del archivo reproyectado y remuestreado, se selecciona únicamente la extensión descrita en los datos polarimétricos.

Todo lo anterior se implementa mediante un intérprete Python, utilizando la librería GDAL: *Geospatial Data Abstraction software Library* [29].

2.5.1.2. Obtención de métricas.

Una vez realizado todo el preprocesamiento ya descrito, se procede a la obtención de las métricas definidas en la etapa de diseño, para toda el área de estudio.

Para la obtención de los parámetros relativos a la Descomposición de Cloude Pottier, se aplica el método *Polarimetric Decomposition* del software SNAP al producto preprocesado, indicando como parámetros la descomposición *H A Alpha*, a una ventana de 5×5 píxeles. Este procesamiento, permite la obtención de los parámetros Entropía, Anisotropía y Alfa, siguiendo la metodología descrita en [21], que fue detallada en el Marco teórico.

Enseguida, se aplica el mismo método antes descrito, indicando esta vez como parámetros, la descomposición de Cloude, en una ventana de 5×5 píxeles. Este procesamiento, permite la obtención de los parámetros Superficie, Volumen y Doble rebote, siguiendo la metodología descrita en [21], también detallada en el Marco teórico.

Para la obtención del parámetro relativo a la Descomposición de Touzi, se aplica nuevamente el método *Polarimetric Decomposition* al producto preprocesado, indicando la aplicación de la descomposición de Touzi, a una ventana de 5×5 píxeles. Dicho método es igualmente incorporado en el software SNAP, siguiendo la metodología descrita en [23], presente en el Marco teórico.

El resultado de cada uno de los procesamientos ya descritos, culmina con la generación de productos ráster, que en sus bandas describen el área de estudio en términos de cada métrica de interés.

Luego de la obtención de dichos productos, se aplica una corrección de terreno a cada una de las bandas de los mismos. Para ello se utiliza el método *Range Doppler Terrain Correction*, incorporado en SNAP (siguiendo la metodología descrita en [30]) con el modelo de elevación digital SRTM 3sec y el método de remuestreo *Nearest Neighbour* a la resolución espacial original del producto.

Por otra parte, en base al producto preprocesado del modelo de elevación digital, se obtienen las métricas de Elevación, Pendiente, Orientación y Sombreado. Esto es implementado en Python, utilizando el método *Dem* de la librería GDAL [29].

2.5.1.3. Exploración.

La presente sección persigue el objetivo de caracterizar cada uno de los polígonos de entrenamiento, así como cada clase identificada, en términos de las diversas métricas ya escogidas. La implementación de lo expuesto en la presente sección se realizó en un intérprete Python.

La discusión de estos resultados, permite una decisión informada sobre qué métricas aportan hacia una clasificación efectiva del área en términos de las clases definidas en el diseño.

A continuación, se muestra, por ejemplo, el análisis realizado para la métrica Entropía.

Inicialmente, se obtiene un mapa de calor mostrando gráficamente los valores que alcanza la métrica en cuestión, para cada uno de los polígonos de entrenamiento identificados. Por ejemplo, en la Figura 2.16, se observan mapas de calor de la métrica Entropía en las turberas de clase Sphagnum.

Para visualizar de mejor manera los resultados, se grafica además, por cada turbera, la función densidad de probabilidad asociada a la métrica. Por ejemplo, para el mismo caso de Entropía en turberas de clase Sphagnum, se puede observar el resultado en la Figura 2.17. Para cada distribución graficada, se incorpora su promedio y desviación estándar. La recta negra punteada indica el promedio de los datos, mientras la recta azul punteada, indica el promedio más una desviación estándar. Es importante destacar, que hay distribuciones en las cuales el promedio y la desviación estándar no son suficientes para un análisis completo de las mismas, por ejemplo, en distribuciones bimodales.

Mapa de calor: Entropía en Turberas Sphagnum

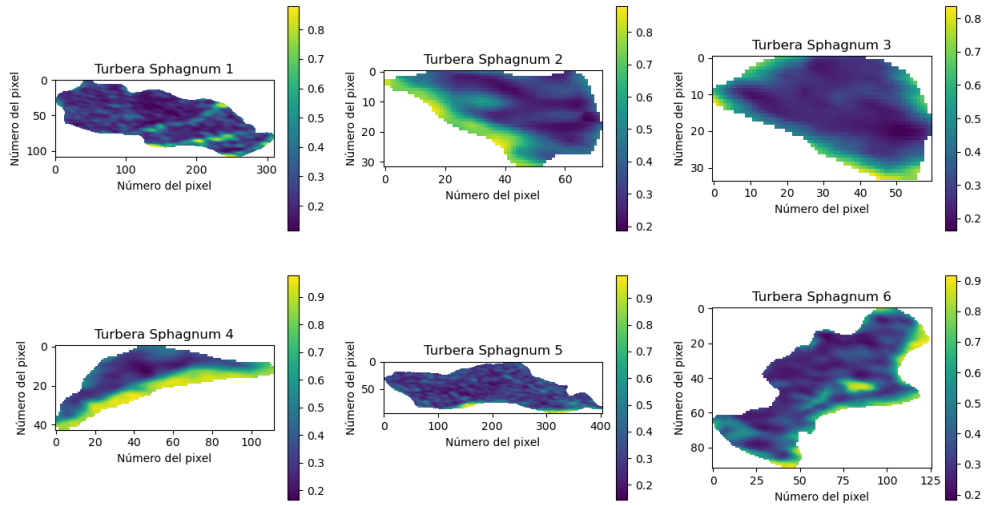


Figura 2.16: Mapa de calor de Entropía para polígonos de Turberas Sphagnum (Elaboración propia).

Histogramas de Entropía en Turberas Sphagnum (individuales)

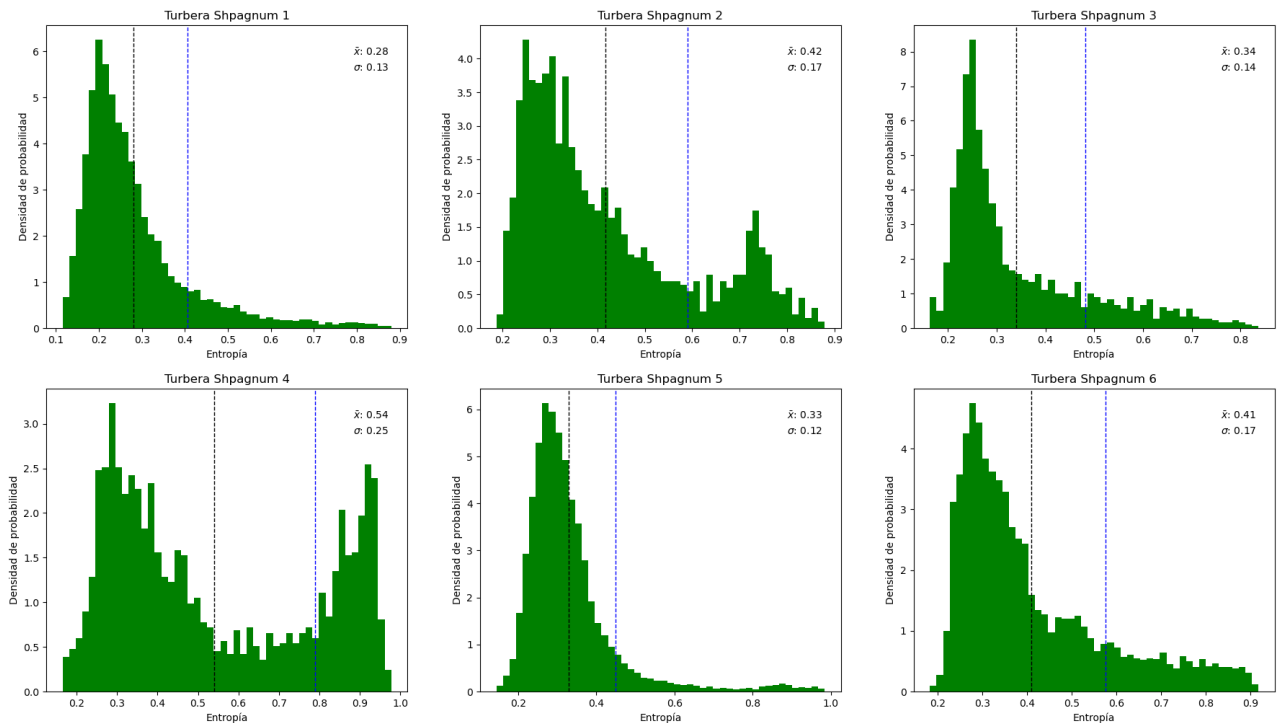


Figura 2.17: Función densidad de probabilidad de Entropía en polígonos de Turberas Sphagnum (Elaboración propia).

El mismo análisis se repite para la clase Otras Turberas, obteniendo los resultados observables en las Figuras 2.18 y 2.19.

Mapa de calor: Entropía en Otras Turberas

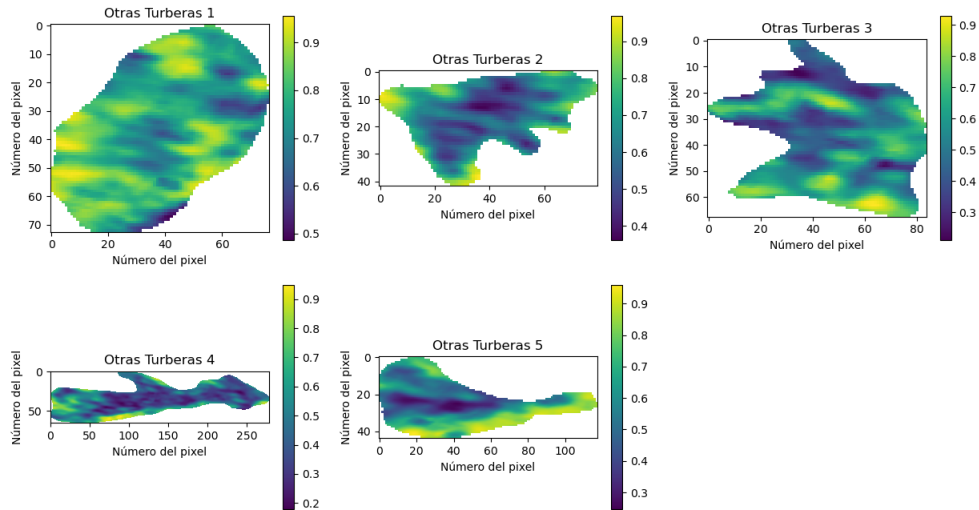


Figura 2.18: Mapa de calor de Entropía para polígonos de Otras Turberas (Elaboración propia).

Histogramas de Entropía en Otras Turberas (individuales)

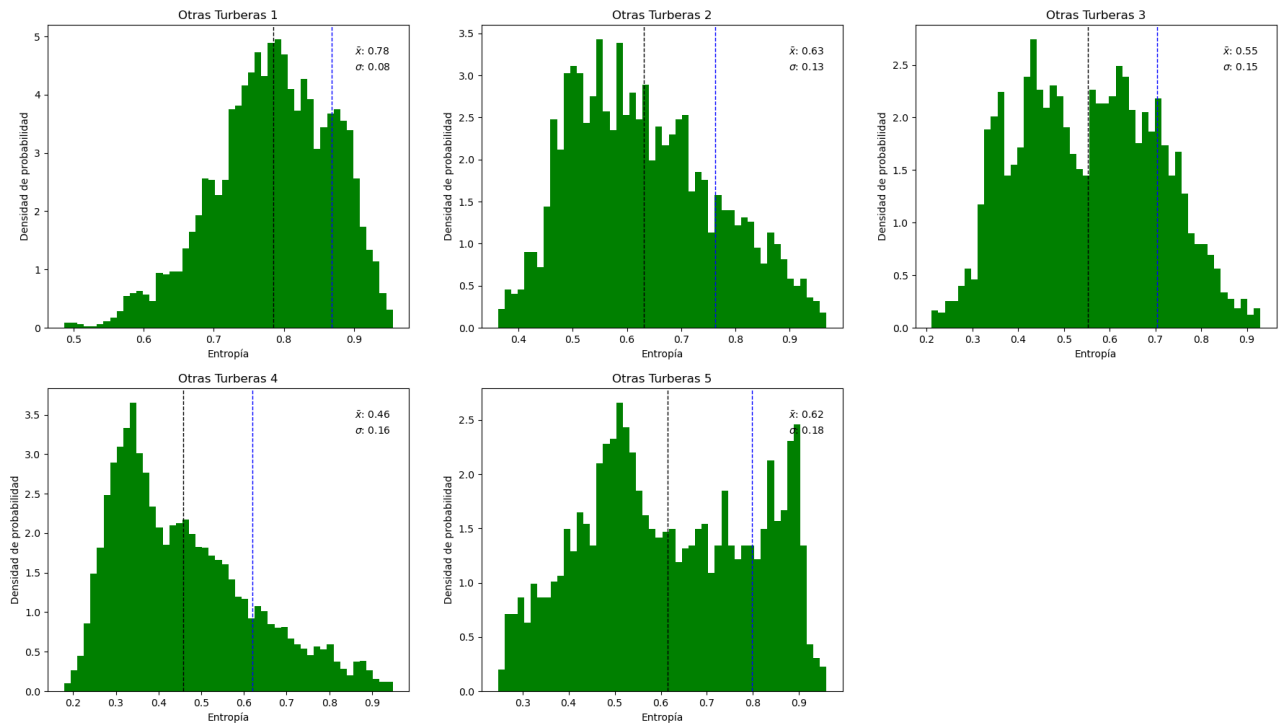


Figura 2.19: Función densidad de probabilidad de Entropía en polígonos de Otras Turberas (Elaboración propia).

Asimismo, para la clase Turberas Impactadas, se obtienen las Figuras 2.20 y 2.21.

Mapa de calor: Entropía en Turberas Impactadas




Figura 2.20: Mapa de calor de Entropía para polígonos de Turberas Impactadas (Elaboración propia).

Histogramas de Entropía en Turberas Impactadas (individuales)




Figura 2.21: Función densidad de probabilidad de Entropía en polígonos de Turberas Impactadas (Elaboración propia).

Para poder comparar de mejor manera entre las funciones densidad de probabilidad dentro de cada una de las clases, se agrupan las curvas de cada clase en un solo gráfico. Por ejemplo, en la Figura 2.22, se puede observar lo descrito para la métrica Entropía. En este caso, las funciones densidad de probabilidad se estiman mediante el método *Kernel Density Estimation*, de la librería *seaborn* [31], para una mejor visualización.

Nuevamente, como se puede observar en la Figura 2.22, se vuelve a computar en cada caso la media y desviación estándar de la métrica, esta vez, para todos polígonos de la clase en cuestión. Se agrega además, la misma recta punteada negra representando gráficamente el promedio \bar{y} , y la recta punteada azul, representando el promedio más una desviación estándar.

Entropía agrupada por clase (método KDE)




Figura 2.22: Entropía agrupada por clase (Elaboración propia).

Finalmente, para resumir el comportamiento de la métrica Entropía en los datos de entrenamiento, se produce un gráfico que permite observar, simultáneamente, las funciones densidad de probabilidad de cada polígono de las tres clases definidas.

Lo anterior se puede observar en la Figura 2.23. Nuevamente, el método *Kernel Density Estimation*, de la librería *seaborn* [31] es escogido para la visualización.

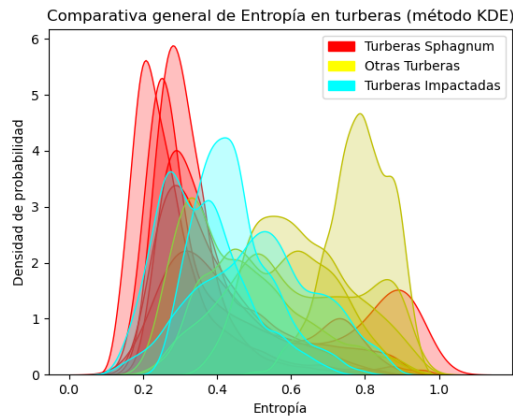
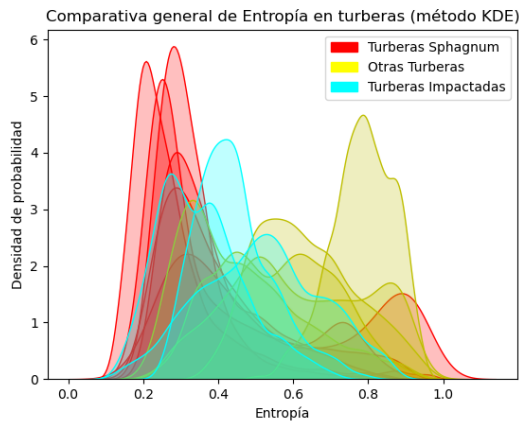


Figura 2.23: Entropía: Gráfico resumen (Elaboración propia).


Este análisis, es repetido para cada una de las once métricas definidas en el diseño. Su detalle se puede consultar en el Anexo A.

Para efectos del análisis a realizar en la presente sección, se presentan los gráficos resumen de cada una de las métricas de estudio en las Figuras 2.24, 2.25, 2.26 y 2.27.


En la Figura 2.24, se presentan los gráficos resumen obtenidos para las métricas: Entropía, Anisotropía y Alfa.



(a) Entropía




(b) Anisotropía




(c) Alfa

Figura 2.24: Resumen de métricas Entropía, Anisotropía y Alfa (Elaboración propia).


Luego, en la Figura 2.25, se presentan los gráficos resumen obtenidos para las métricas: Superficie, Volumen y Doble rebote.



(a) Superficie



(b) Volumen



(c) Doble rebote

Figura 2.25: Resumen de métricas Superficie, Volumen y Doble rebote (Elaboración propia).

Enseguida, en la Figura 2.26, se presenta el gráfico resumen obtenido para la métrica Phi.




Figura 2.26: Resumen de métrica Phi (Elaboración propia).

Finalmente, en la Figura 2.27, se presentan los gráficos resumen obtenidos para las métri-

cas: Elevación, Pendiente, Orientación y Sombreado.

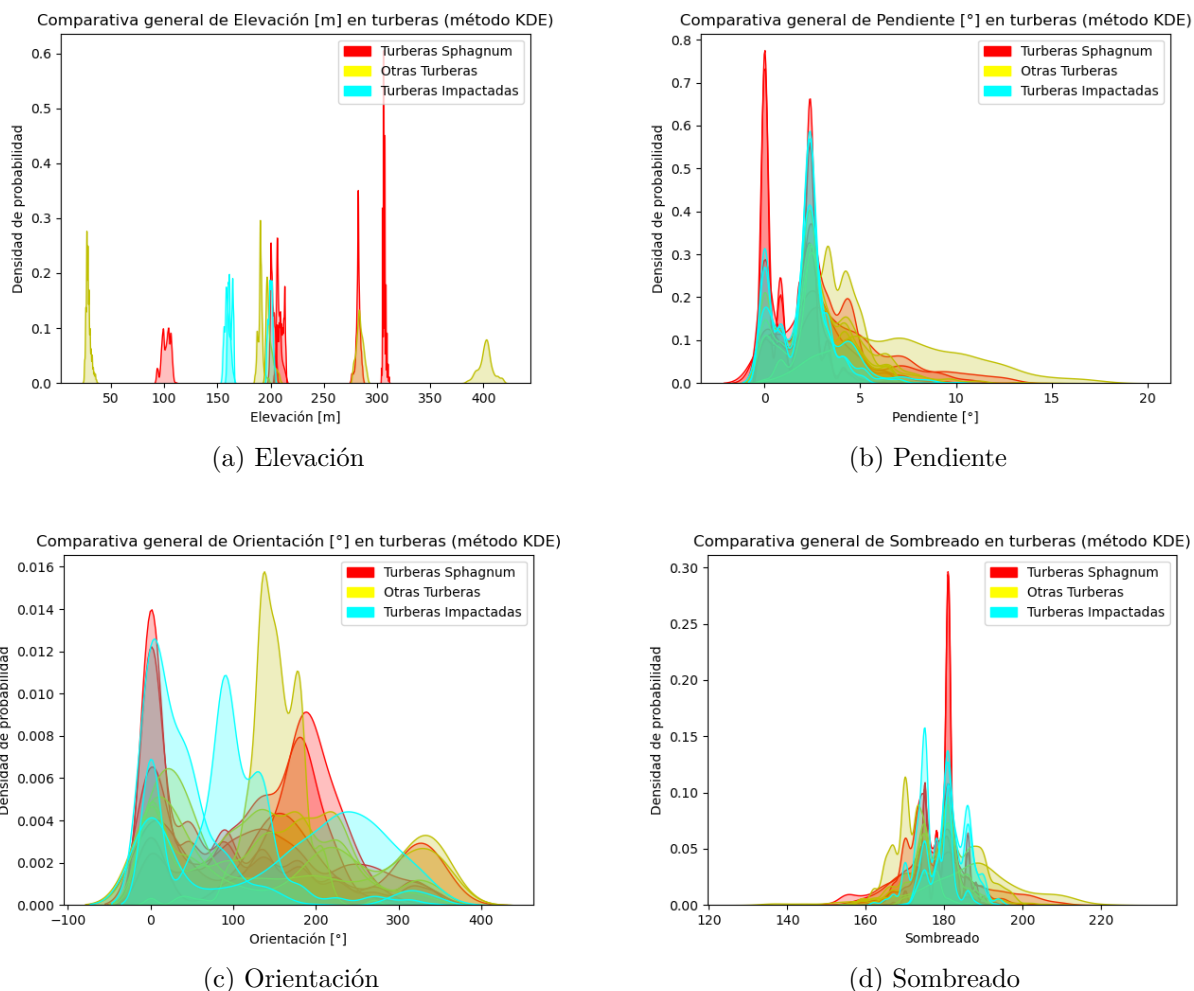


Figura 2.27: Resumen de métricas Elevación, Pendiente, Orientación y Sombreado (Elaboración propia).

2.5.1.4. Análisis.

A continuación se presenta un breve análisis de cada métrica explorada, recordando claves para su interpretación y discutiendo sus distribuciones en los polígonos de entrenamiento.

2.5.1.4.1. Entropía.

En la Figura 2.24 (a), se muestra el gráfico resumen del comportamiento de la métrica Entropía en cada uno de los polígonos de entrenamiento (seis polígonos de la clase Turberas Sphagnum, cinco de la clase Otras Turberas y tres de la clase Turberas Impactadas).

Dicha métrica, como ya se comentó anteriormente, permite categorizar al objetivo en términos de la aleatoriedad de la información generada en su matriz de coherencia. Valores cercanos a cero, indican la fuerte presencia de un único mecanismo de retrodispersión dominante, mientras valores cercanos a uno, indican la aleatoriedad en la retrodispersión.

En la Figura 2.24 (a), al comparar las distribuciones de entre clases, se puede observar que las funciones densidad de probabilidad de cada una de las tres clases se concentran (en mayor medida) en diferentes tramos del espectro de la métrica Entropía. Esto la convierte en una característica relevante a la hora de la distinción entre cada una de ellas.

Ahora, al analizar en específico la clase Sphagnum, se observan funciones densidad de probabilidad bastante uniformes entre los diversos polígonos de entrenamiento, lo que invita a concluir un preciso etiquetado de los mismos. Se tiene una media general de 0,33 y una desviación estándar de 0,15, desprendiéndose la presencia dominante de un mecanismo de retrodispersión.

En la clase Turberas Impactadas, se observan tres funciones densidad de probabilidad, con una media general de 0,46 y una desviación estándar de 0,15. No se observa de manera clara una curva uniforme entre los polígonos, pero sí, una fuerte concentración de los datos en la parte media del espectro. Se cree que incorporar más polígonos de entrenamiento en esta clase sería fundamental para consolidar una curva característica.

Finalmente, para la clase Otras Turberas, se observan funciones densidad de probabilidad que difieren sustancialmente entre sí, además de abarcar prácticamente todo el espectro de valores de Entropía. Se tiene una media de 0,56 y una mayor desviación estándar, de 0,19. Se concluye entonces, de manera preliminar, que no hay un comportamiento único respecto de la métrica Entropía en los polígonos de esta clase. Como se verá en lo sucesivo, este es un comportamiento recurrente en el análisis de las diversas métricas para esta clase.

2.5.1.4.2. Anisotropía.

En la Figura 2.24 (b), se muestra el gráfico resumen del comportamiento de la métrica Anisotropía en los polígonos de entrenamiento.

Dicha métrica, permite categorizar al objetivo en términos de la importancia relativa entre los segundos y terceros mecanismos de retrodispersión (valores propios de la matriz de coherencia). Se trata de una métrica normalizada entre cero y uno: a mayor importancia relativa, mayor Anisotropía.

Esta métrica toma relevancia cuando se tienen valores altos de Entropía, mayores a 0,7 según [22]. Estos valores se dan principalmente en la clase Otras Turberas, que presenta un promedio de 0,56 y una desviación estándar de 0,19.

De manera inicial, no se observa una diferenciación clara de las curvas densidad de probabilidad entre clases. Se tienen, en general, curvas bastante aglutinadas en un mismo sector del espectro, independiente la clase en cuestión. Esta idea se refuerza con los promedios y desviaciones estándar de cada clase, de: 0,29 y 0,11, respectivamente, para la clase Sphagnum; 0,26 y 0,11 para Otras Turberas; y 0,29 y 0,14 para Turberas Impactadas.

Esto la convierte en una característica poco relevante a la hora de la distinción entre cada una de las clases. Sin embargo, como ya se comentó, aporta información sobre la retrodispersión en casos con Entropía mayor que 0,7.

2.5.1.4.3. Alfa.

En la Figura 2.24 (c), se muestra el gráfico resumen del comportamiento de la métrica Alfa en los polígonos de entrenamiento.

Dicha métrica, como ya se comentó anteriormente, permite categorizar al objetivo en términos de la naturaleza de la retrodispersión. Valores cercanos a 0° , indican una retrodispersión preponderantemente superficial, valores cercanos a 45° , indican una retrodispersión por volumen y valores cercanos a 90° , retrodispersión por rebote par.

Se puede observar que en este caso, tal como en la métrica Entropía, hay un comportamiento diferenciable al comparar cada una de las clases en términos de sus funciones densidad de probabilidad. Las clases funciones de densidad se concentran, en general, en diversos tramos del espectro. Se trata entonces, de manera intuitiva, de una característica que pudiese ser relevante a la hora de la distinción entre cada una de ellas.

En específico, para la clase Sphagnum, se observan funciones densidad de probabilidad bastante uniformes entre los diversos polígonos de entrenamiento, con un promedio de $12,41^\circ$ y una desviación estándar de $7,27^\circ$. Esta clase, presenta entonces una retrodispersión sustancialmente superficial, lo cual es bastante intuitivo considerando su composición física.

Se trata de datos especialmente poco dispersos, lo que, de nuevo, invita a concluir un preciso etiquetado de los mismos.

En la clase Turberas Impactadas, se tiene una media general de $17,90^\circ$ y una desviación estándar de $10,28^\circ$. Estos valores de Alfa quedan un poco por sobre el caso de la Turberas Sphagnum, pero aún, mostrando una retrodispersión superficial en términos generales. Esto pudiese ser atribuible a la erosión del terreno, propia de las actividades extractivas en las turberas.

Los valores de Alfa para esta clase, son también, poco dispersos, invitando a concluir un buen etiquetado.

Finalmente, para la clase Otras Turberas, se tiene una media de $23,50^\circ$ y una desviación estándar de $10,28^\circ$. Se trata de valores de Alfa que indican una retrodispersión que oscila entre superficial y por volumen. Sin embargo y al igual que para la métrica Entropía, dentro de esta misma clase se observan distribuciones de probabilidad bastante diversas entre sí, ocupando un amplio tramo del espectro analizado.

2.5.1.4.4. Superficie.

En la Figura 2.25 (a), se muestra el gráfico resumen del comportamiento de la métrica Superficie en los polígonos de entrenamiento.

Dicha métrica también apunta hacia categorizar al objetivo según el tipo de retrodispersión.

Según [21], en objetivos con retrodispersión superficial, la métrica aquí denominada Superficie, es mayor que las métricas Volumen y Doble Rebote. En objetivos con retrodispersión por volumen, la métrica Volumen es mayor que Superficie y Doble rebote. Y por último, en objetivos con retrodispersión por rebotes par, la métrica Doble Rebote es mayor que las métricas Superficie y Volumen.

Comparando los valores alcanzados para estas tres métricas en cada una de las clases, se evidencia que en general, la métrica Superficie se mantiene por sobre las métricas de Volumen y Doble Rebote. Según esto, se trata entonces, de una retrodispersión preponderantemente superficial en todas las clases, en concordancia con lo ya analizado de la métrica Alfa.

En el caso específico de la métrica Superficie, como se puede observar en la Figura 2.25 (b), no se logran identificar distribuciones de probabilidad distintivas según la clase en cuestión. Se tienen curvas aglutinadas en un sector del espectro, independiente de la clase a la que pertenecen. Lo anterior, se reafirma con el promedio y desviación estándar de cada clase, de $-3,14$ y $2,07$, respectivamente, para las Turberas Sphagnum, $-3,28$ y $3,72$ para las Turberas Impactadas y $-4,01$ y $2,60$ para la clase Otras Turberas.

Esto va en desmedro de la posibilidad de diferenciar clases en base a esta única métrica.

2.5.1.4.5. Volumen.

En la Figura 2.25 (b), se muestra el gráfico resumen del comportamiento de la métrica Volumen en los polígonos de entrenamiento.

Nuevamente, como se puede observar, no se logran identificar distribuciones de probabilidad distintivas según la clase en cuestión. Se tienen curvas aglutinadas en un sector del espectro, independiente de su clase. La clase Turberas Sphagnum, presenta un promedio de $-33,30$ y una desviación estándar de $6,04$, la clase Turberas Impactadas, un promedio de $-30,25$ y una desviación estándar de $7,57$ y finalmente, la clase Otras Turberas, un promedio de $-28,59$ y una desviación estándar de $7,21$.

Se anticipa una pobre capacidad de clasificación entre clases en base a esta única métrica.

2.5.1.4.6. Doble Rebote.

En la Figura 2.25 (c), se muestra el gráfico resumen del comportamiento de la métrica Doble rebote en los polígonos de entrenamiento.

Nuevamente no se logran identificar distribuciones de probabilidad distintivas según su clase. La clase Turberas Sphagnum, presenta un promedio de $-28,89$ y una desviación estándar de $5,46$, la clase Turberas Impactadas, un promedio de $-26,58$ y una desviación estándar de $6,72$ y finalmente, la clase Otras Turberas, un promedio de $-25,60$ y una desviación estándar de $6,13$.

De nuevo, se anticipa una pobre capacidad de clasificación entre clases en base a esta única métrica.

2.5.1.4.7. Phi.

En la Figura 2.26, se muestra el gráfico resumen del comportamiento de la métrica Phi en los polígonos de entrenamiento.

Dicha métrica, como ya se comentó anteriormente, ha sido previamente explorada para el mapeo de turberas.

Como se puede observar en la Figura 2.26, la métrica por sí sola tiene una pobre capacidad de discriminación entre las clases definidas en el presente trabajo.

Para la clase Turberas Sphagnum, presenta un promedio de 0,28 y una desviación estándar de 0,50. Para la clase Turberas Impactadas, 0,21 y 0,39, respectivamente. Finalmente, para la clase Otras Turberas, 0,26 y 0,45, respectivamente.

2.5.1.4.8. Elevación, Pendiente, Orientación y Sombreado.

En la Figura 2.24, se muestra el gráfico resumen del comportamiento de las métricas Elevación, Pendiente, Orientación y Sombreado, en los polígonos de entrenamiento.

Es importante recordar, que dichas métricas son obtenidas de un modelo de elevación digital y que no corresponden a información sobre la retrodispersión del objetivo. Se trata en este caso, de información topográfica de la zona donde se ubican los polígonos.

De todas maneras, esta información es clave para un mapeo efectivo de la zona. No tanto para la distinción entre clases, como para la clasificación macro, entre zonas que no corresponden a turberas y zonas que sí.

Sobre la métrica Elevación, observable en la Figura 2.24 (a), se evidencia que los polígonos identificados presentan una altitud que no supera los 500[msnm]. No se observa un comportamiento diferenciable por clases.

Sobre la métrica Pendiente, observable en la Figura 2.24 (b), se evidencia un comportamiento bastante uniforme entre las clases, con valores mayormente entre 0 y 5°. Se trata, como es de esperar, de zonas con escasa pendiente, que permiten la acumulación de cuerpos de agua.

La métrica Orientación es observable en la Figura 2.24 (c). En esta implementación, los 0° representan la orientación Norte, los 90° la orientación Este, los 180° la orientación Sur y los 270° la orientación Oeste. Cabe destacar además, que a las zonas de pendiente nula, se les asigna el valor 0° para evitar presencia de nulos.

Se observa que no existe una correlación entre las clases identificadas (ni individual ni colectivamente) con la orientación topográfica del territorio.

Finalmente, la métrica Sombreado, que reproduce la iluminación hipotética del terreno a una fuente artificial de luz, comúnmente utilizada para visualizar efectivamente el territorio, tampoco permite una diferenciación entre clases.

2.5.2. Fase Implementación del clasificador

En esta sección, se detallan los resultados obtenidos en cada hito de la fase Implementación del clasificador.

2.5.2.1. Preprocesamiento.

Inicialmente, con ayuda de las librerías GDAL [29] y Pandas [32], se realiza un preprocesamiento que permite transformar los archivos ráster de entrada, a objetos del tipo *pandas.DataFrame*. En ellos, los datos son estructurados como sigue: cada fila, representa un píxel y cada columna una métrica.

Se establecen dos conjuntos de datos principales con los que se trabaja. Por un lado, el conjunto de datos etiquetados, que contempla todos los píxeles comprendidos dentro de los polígonos de entrenamiento, con sus debidas etiquetas. Se trata de un conjunto de 82.006 píxeles etiquetados, con las 11 métricas descritas en la sección 2.4.1.4, por cada uno de ellos.

En el conjunto de datos etiquetados, hay un total de 7.724 píxeles de la clase Turberas Impactadas (9, 42%), 21.891 píxeles de la clase Otras Turberas (26, 69%) y 52.391 píxeles de la clase Turberas Sphagnum (63, 89%).

Por otro, está el conjunto de datos sin etiquetar, que contempla todos los píxeles del área de estudio y, tal como su nombre lo indica, no incorpora etiquetas de clase. En este caso, se dispone de un total de 14.066.689 de píxeles, con las 11 métricas de la sección 2.4.1.4 para cada uno de ellos.

2.5.2.2. Generación de datos de entrenamiento y validación.

En base al conjunto de datos etiquetados, se genera un conjunto de datos de entrenamiento y otro de validación. El conjunto de datos de entrenamiento, corresponde al 70% del conjunto de datos etiquetados, mientras que el 30% restante, corresponde al conjunto de datos de validación. Esta separación se realiza de manera estratificada, es decir, manteniendo la proporción de datos de cada clase etiquetada en cada uno de los conjuntos de datos generados.

La implementación de lo anterior se lleva a cabo mediante la librería *scikit learn* [33] de Python.

Es importante mencionar que esta separación de los datos se mantiene para cada una de las clasificaciones realizadas, que son detalladas en lo sucesivo.

2.5.2.3. Normalización de los datos.

Dadas las diferencias de unidades y magnitudes de las diversas métricas exploradas, se realiza una normalización de los datos de entrada, que permita una adecuada incorporación de los mismos en los diversos algoritmos de clasificación implementados.

Para ello, se utiliza el método *StandardScaler* de la librería *scikit learn* [33]. Este genera, para cada métrica, distribuciones de media cero y desviación estándar unitaria.

2.5.2.4. Definición y entrenamiento de algoritmos de clasificación supervisada a utilizar.

Se define explorar la implementación de algoritmos de clasificación supervisada de tres tipos: Regresor Logístico (binario), Bosque Aleatorio y Red Neuronal.

El Regresor Logístico, se implementa mediante el método *LogisticRegression* de la librería *scikit learn* [33]. Algunos de los parámetros más relevantes con los que se implementa el clasificador son los siguientes:

- Binario (esquema de uno contra todos)
- Penalización de tipo L2 al sobreajuste de los datos.
- Tasa de regularización de 0,001.
- Balanceo de pesos (peso inversamente proporcional a la frecuencia de la clase).
- Cálculo de pérdida con Entropía cruzada.

Por su parte, la Red Neuronal se implementa mediante el método *Sequential* de la librería *TensorFlow* [34]. A continuación se describen (a grandes rasgos) las características de la red implementada.

- Tasa de Aprendizaje: 0,001.
- Función de pérdida: Entropía cruzada.
- Número de épocas: 70.
- Capa de entrada con función ReLU.
- Capa oculta de 10 nodos con función ReLU.
- Capa de salida con función SoftMax.

Finalmente, el algoritmo de tipo Bosque Aleatorio, se implementa mediante el método *RandomForest* de la misma librería [33]. Algunos de sus parámetros más relevantes son:

- Número de árboles: 100.
- Criterio de separación: Impureza de Gini.
- Profundidad máxima: Hasta que todas las hojas sean puras.
- Mínimas muestras para dividir un nodo interno: 2.
- Mínimas muestras para ser un nodo hoja: 1.
- Número de métricas seleccionadas por cada árbol: $\sqrt{11} = 3,32 \sim 3$.

Cada uno de los clasificadores recién mencionados, es entrenado con el mismo conjunto de datos de entrenamiento ya mencionado anteriormente.

2.5.2.5. Obtención y análisis de métricas de desempeño.

Una vez entrenados los modelos, se entrega como entrada a cada uno de ellos, el conjunto de validación anteriormente descrito.

Con las clasificaciones predichas por cada algoritmo, se computan diversas métricas de desempeño que se comentan a continuación.

En la Figura 2.28, se presenta la matriz de confusión generada por la clasificación del algoritmo Regresor Logístico. Se observa allí, el número de clasificaciones asignadas a cada clase, así como la clase real de cada píxel. Las predicciones correctas por cada clase, por ejemplo, se pueden visualizar en la diagonal.

En este caso, salta a la vista la baja cantidad de píxeles clasificados correctamente como Turberas Impactadas. De hecho, la cantidad de píxeles clasificados correctamente como Turberas Impactadas, es menor que cualquier otra predicción que involucra a la clase. Esto revela un pobre desempeño del clasificador.

Se hace evidente además, el fuerte desbalance entre las clases analizadas. Esto se sigue observando en todas las matrices de confusión aquí detalladas.




Figura 2.28: Matriz de confusión del Regresor Logístico (Elaboración propia).

La tasa de Aciertos, corresponde a la fracción de ejemplos del total, que son correctamente clasificados. La Precisión, por su parte, corresponde a la fracción de ejemplos asignados a la clase i , que efectivamente son de la clase i . Finalmente, la Recuperación, corresponde a la fracción de ejemplos efectivos de la clase i , que son correctamente clasificados.


En la Tabla 2.3, se pueden observar las métricas de Acierto, Precisión y Recuperación para el algoritmo Regresor Logístico. Estas son calculadas mediante un promedio macro, es decir, computando las métricas para cada clase y luego promediándolas. Este método de cómputo, favorece la representación de las clases minoritarias en las métricas.

Se puede observar que el algoritmo tiene un muy pobre desempeño en sus métricas de Precisión y Recuperación. En gruesa medida, esto es reflejo de un muy mal desempeño en la clasificación de las Turberas Impactadas.

Tabla 2.3: Macro-métricas de desempeño del Regresor Logístico.

Aciertos	0,74
Precisión	0,56
Recuperación	0,56

En la Figura 2.29 (a) se presenta la matriz de confusión generada por la clasificación de la Red Neuronal. Por su parte, en la Figura 2.29 (b), se muestra un gráfico de la función de pérdida de la red a lo largo de las épocas de entrenamiento (tanto para el conjunto de entrenamiento, como el de validación).



(a) Matriz de confusión de Red Neuronal.

(b) Pérdida versus épocas en Red Neuronal.

Figura 2.29: Desempeño Red Neuronal (Elaboración propia).

Como se observa, la pérdida en el conjunto de entrenamiento va disminuyendo mientras avanzan las épocas. Lo propio sucede con el conjunto de validación, permitiendo inferir que el modelo no está sobreajustado a los datos.

En este caso, la clasificación es bastante más exitosa. Como se puede ver en la Tabla 2.4, se tienen valores de Acierto, Precisión y Recuperación muy cercanos a 1. Esto también se observa en la matriz de confusión, con escasos elementos fuera de su diagonal.

Finalmente, en la Figura 2.30, se muestra la matriz de confusión obtenida en el algoritmo

Tabla 2.4: Macro-métricas de desempeño de la Red Neuronal.

Aciertos	0,98
Precisión	0,98
Recuperación	0,98

Bosque Aleatorio. Se observa un excelente desempeño del modelo, con muy pocos elementos fuera de la diagonal.




Figura 2.30: Matriz de confusión del Bosque Aleatorio (Elaboración propia).

Lo anterior se reafirma al calcular las métricas de desempeño del modelo, observables en la Tabla 2.5.

Tabla 2.5: Macro-métricas de desempeño del Bosque Aleatorio.

Aciertos	1,00
Precisión	1,00
Recuperación	1,00

En la Tabla 2.6 se puede observar el ranking de características del algoritmo Bosque Aleatorio. Este es calculado según [33], en base al criterio de importancia de Gini. Mientras más alto es el número informado, mayor es la importancia de la característica. Se destacan las métricas Elevación, Alfa y Entropía como las más relevantes.

Esto es concordante con el análisis realizado de manera exploratoria. Tanto en las métricas Alfa como Entropía, se observan distribuciones bastante uniformes inter-clase (con mayor heterogeneidad en la clase Otras Turberas) y, al comparar dichas distribuciones entre clases, se observan tendencias diferenciadas. Por su parte, la Elevación, si bien no se trata de una métrica indicativa de la retrodispersión del objetivo, permite recoger características físicas del entorno en donde yace este tipo de ecosistemas y se transforma en la métrica de mayor importancia en la clasificación.

Tabla 2.6: Ranking de características en Bosque Aleatorio

Alfa	0,13001
Anisotropía	0,0247
Doble Rebote	0,02792
Entropía	0,10464
Phi	0,01608
Superficie	0,07326
Volumen	0,03107
Elevación	0,5011
Pendiente	0,04285
Orientación	0,02781
Sombreado	0,02057

2.5.2.6. Ampliación de la clasificación a toda el área de estudio.

Para finalizar con la fase de implementación, se ingresan como entrada a cada uno de los clasificadores anteriormente mencionados, el conjunto de datos no etiquetados, correspondientes a la extensión completa del área de estudio.

Es importante mencionar que existe una diferencia sustancial entre el conjunto de datos etiquetados y no etiquetados. Y es que en el conjunto de datos etiquetados, todos los elementos (o píxeles), corresponden efectivamente a alguna de las tres clases del modelo: Sphagnum, Impactadas o Otras Turberas. Sin embargo, en el conjunto de datos no etiquetados, correspondientes a toda el área de estudio, evidentemente existen coberturas de suelo (y píxeles en última instancia) que no corresponden a ninguna de estas tres clases.

Para incorporar la posibilidad de no asignar ninguna clase en el mapeo, se utiliza un umbral de decisión. Dicho umbral asigna efectivamente una etiqueta de clase a un píxel, únicamente si la probabilidad de pertenencia de dicho píxel a la clase (obtenida de las variables de salida del modelo), supera un cierto umbral.

Una vez clasificados cada uno de los píxeles del conjunto de datos, se transforma y guarda la información producida en un archivo raster de una banda, indicando la clase resultante por cada píxel. Lo anterior, gracias a las librerías [32] y [29].

A continuación, se muestran los diversos mapas de clasificación resultantes y se comen-

tan los resultados. Como se puede observar, cada mapa se define mediante el nombre del clasificador utilizado, así como la magnitud del umbral de decisión. Para cada algoritmo, se prueban diversos umbrales de decisión y se analizan los resultados obtenidos.

En la Figura 2.31, se puede observar la clasificación realizada mediante el algoritmo Regresor Logístico, con un umbral del 50 %.

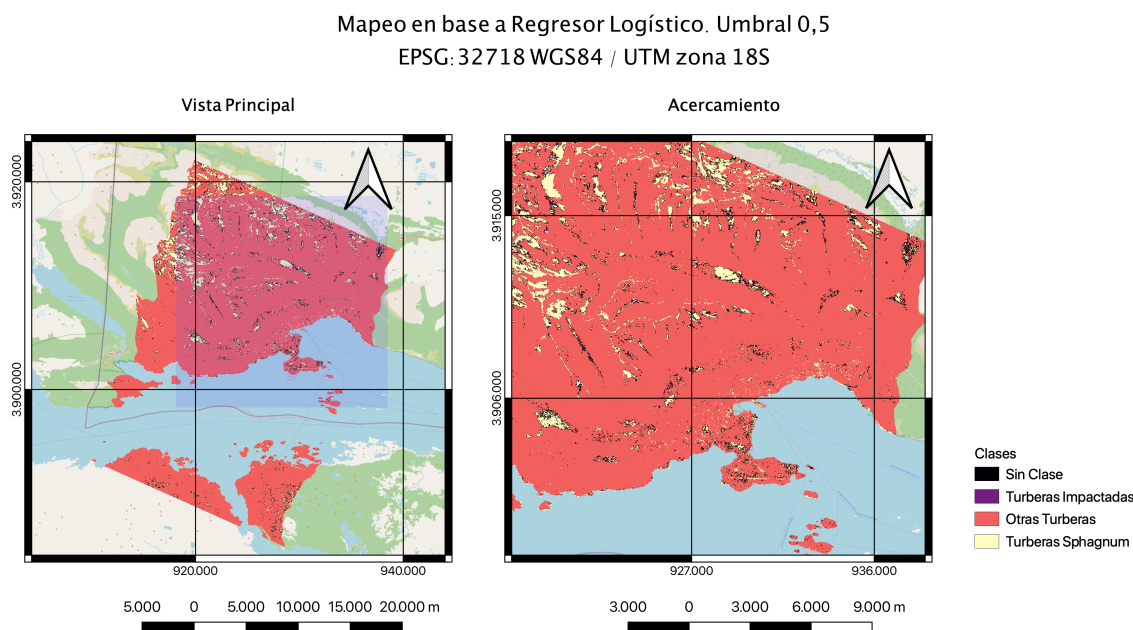


Figura 2.31: Clasificación en base a Regresor Logístico con umbral de 0.5 (Elaboración propia).

Una de las primeras observaciones que salta a la vista es la sobrerrepresentación de la clase Otras Turberas. Como se puede observar en la Figura 2.31, con un umbral del 50 %, prácticamente toda el área de estudio es considerada entre alguna de las tres clases de turberas, lo cual de manera evidente es un error.

Se observa además una muy baja identificación de Turberas Impactadas, incluso en aquellas zonas donde se identificaron polígonos de entrenamiento. Esto vuelve a recordar el mal desempeño del clasificador Regresor Logístico en la identificación de Turberas Impactadas, como ya se discutió previamente.

Sobre la clase Turberas Sphagnum, se observa un desempeño aceptable en las áreas con presencia de polígonos de entrenamiento. No obstante, al comparar el resultado con imágenes de alta resolución en el software *Google Earth*, se evidencia que el desempeño del modelo, en términos de la generalización de la clasificación de turberas de la clase Sphagnum, no es óptimo. El modelo no logra clasificar de buena manera los polígonos de entrenamiento, ni menos generalizar la clasificación.

En la Figura 2.32, se puede observar la clasificación realizada mediante el algoritmo Re-

gresor Logístico, con un umbral del 70 %.

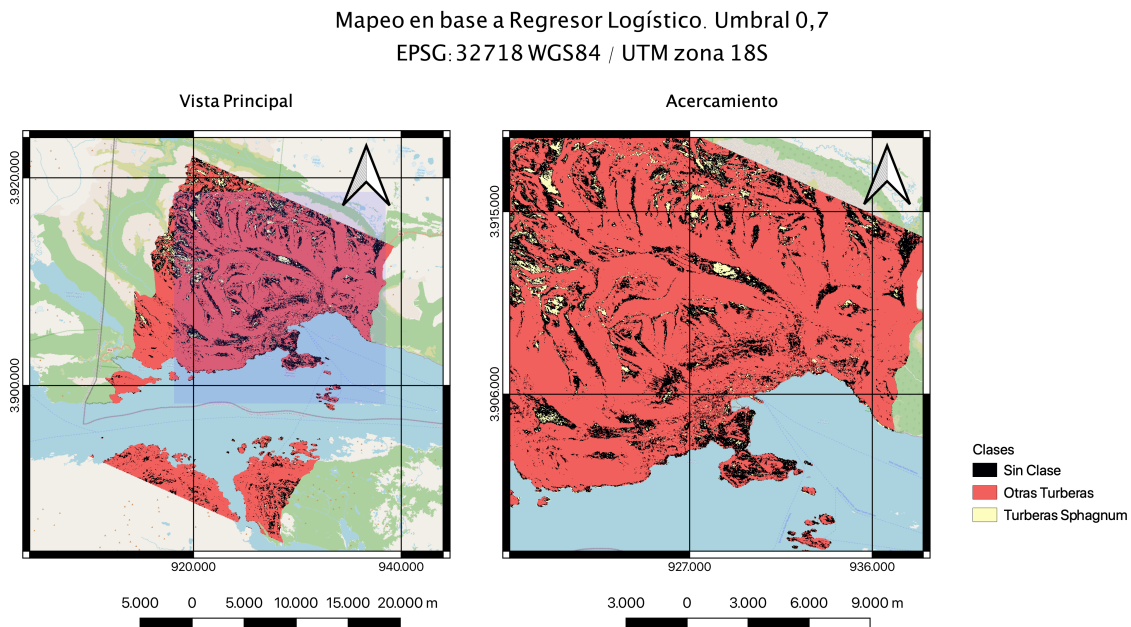


Figura 2.32: Clasificación en base a Regresor Logístico con umbral de 0.7 (Elaboración propia).

Como se puede observar en la Figura 2.32, al aumentar el umbral de decisión del Regresor Logístico a un 70 %, si bien aumentan en alguna medida la cantidad de píxeles sin clase, el problema de la sobrerrepresentación de la clase Otras Turberas se mantiene presente.

En esta clasificación, no se identifica ningún píxel de la clase Turberas Impactadas, lo que refuerza la idea ya mencionada de la deficiencia de este modelo.

Por su parte, las áreas clasificadas como Turberas Sphagnum disminuyen considerablemente, perdiendo incluso, áreas comprendidas dentro de los polígonos de entrenamiento.

En la Figura 2.33, se puede observar la clasificación realizada mediante la Red Neuronal, con un umbral del 95 %.

Mapeo en base a Red Neuronal. Umbral 0,95
EPSG: 32718 WGS84 / UTM zona 18S

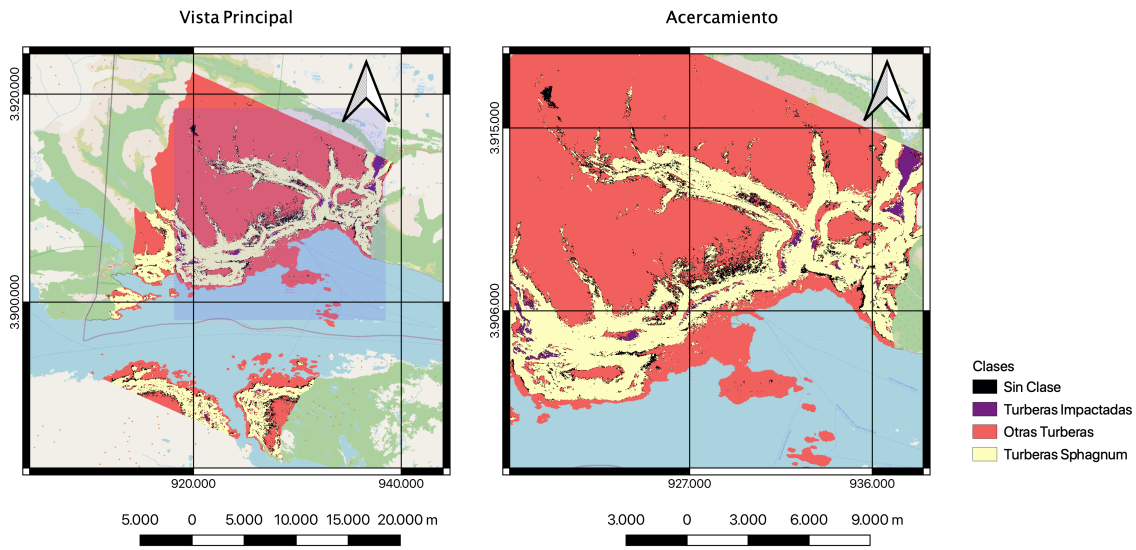


Figura 2.33: Clasificación en base a Red Neuronal con umbral de 0.95 (Elaboración propia).

Sobre la clasificación de Otras Turberas en este modelo, se vuelve a evidenciar una sobre-representación de la clase. Esto de manera aún más evidente que para el caso del Regresor Logístico, dejando escasas zonas sin clasificación.

Este comportamiento es compartido por la clase Turberas Sphagnum, que particularmente también se observa sobrerrepresentada en el modelo.

Al comparar el resultado con imágenes de alta resolución en el software *Google Earth*, se evidencia que si bien la clasificación de turberas de las clase Impactadas funciona correctamente para las áreas descritas por los polígonos de entrenamiento (o zonas aledañas a ellas), se ve bastante sobrerrepresentada en zonas que no existe la presencia de dichas turberas.

En la Figura 2.34, se puede observar la clasificación realizada mediante la Red Neuronal, con un umbral del 99,9 %.

Mapeo en base a Red Neuronal. Umbral 0,999
EPSG: 32718 WGS84 / UTM zona 18S

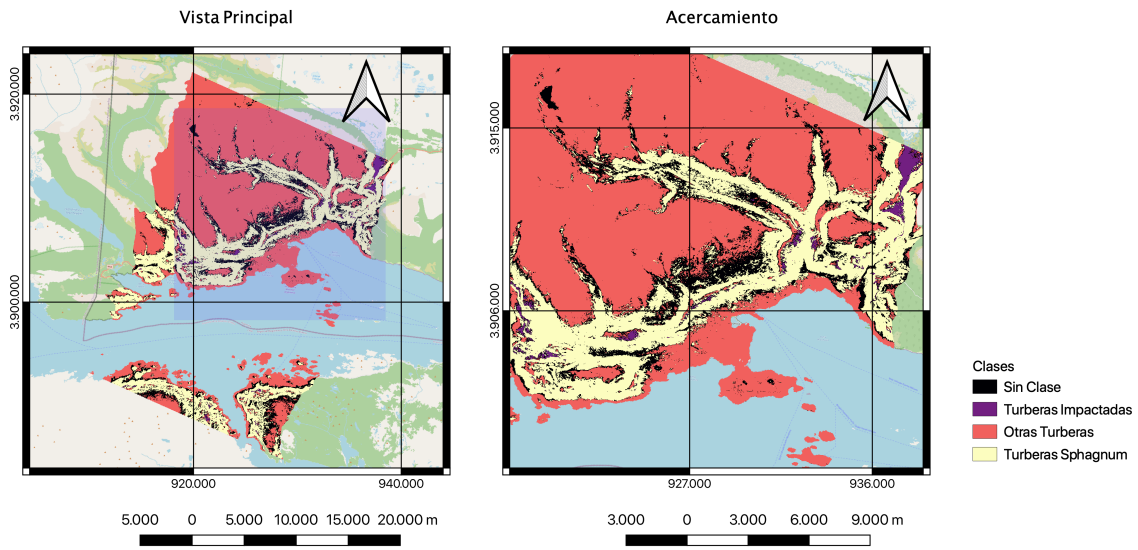


Figura 2.34: Clasificación en base a Red Neuronal con umbral de 0.999 (Elaboración propia).

Al aumentar el umbral de decisión a un 99,9 %, se observa que el grueso de los problemas ya mencionados con el presente modelo de clasificación se mantienen.

Si bien se observa un leve aumento de las zonas sin clasificar, la sobrerrepresentación de todas las clases se mantiene. Finalmente, cabe destacar que se explora aumentar aún más el umbral, pero no genera mejores resultados.

En la Figura 2.35, se puede observar la clasificación realizada mediante el algoritmo Bosque Aleatorio, con un umbral del 70 %.

Mapeo en base a Bosque Aleatorio. Umbral 0,7
EPSG: 32718 WGS84 / UTM zona 18S

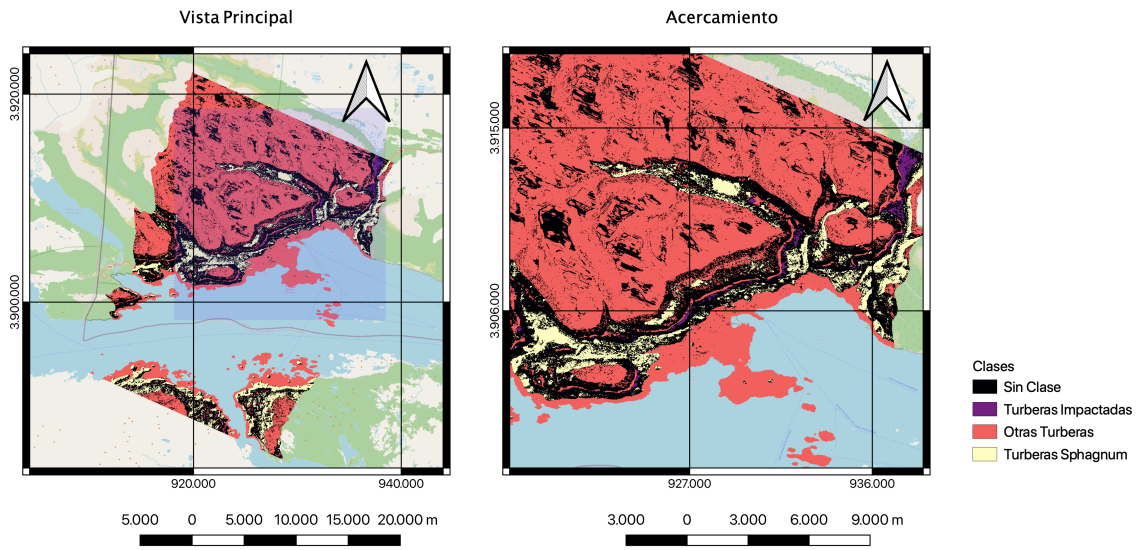


Figura 2.35: Clasificación en base a Bosque Aleatorio con umbral de 0.7
(Elaboración propia).

En esta clasificación, se vuelve a evidenciar el problema de sobrerrepresentación de la clase Otras Turberas. Sin embargo, de todas maneras, se observa una disminución de los píxeles asignados a dicha clase y un aumento considerable de la cantidad de píxeles sin clase.

En el caso de la clasificación de Turberas Sphagnum, se observa un comportamiento bastante mejor que en todas las clasificaciones anteriormente presentadas. Al comparar el resultado con imágenes de alta resolución en el software *Google Earth*, se observa de todos modos una leve sobrerrepresentación de la clase. Sin embargo, el algoritmo logra efectivamente generalizar la clasificación a los nuevos datos ingresados.

Respecto a la clase Turberas Impactadas, el análisis se repite.

En la Figura 2.36, se puede observar la clasificación realizada mediante el algoritmo Bosque Aleatorio, con un umbral del 85 %

Mapeo en base a Bosque Aleatorio. Umbral 0,85
EPSG: 32718 WGS84 / UTM zona 18S

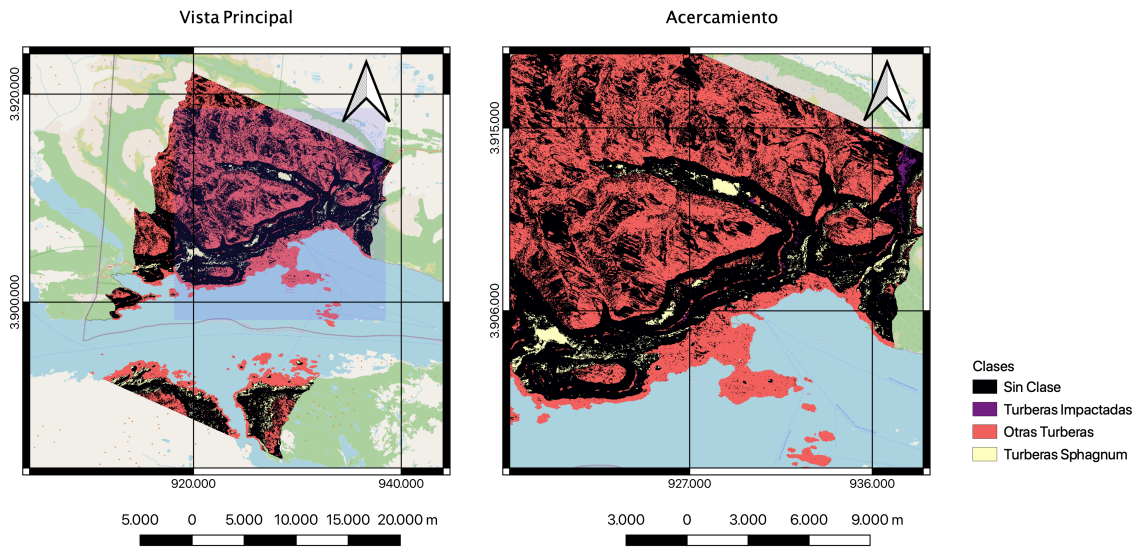


Figura 2.36: Clasificación en base a Bosque Aleatorio con umbral de 0.85 (Elaboración propia).

Al aumentar el umbral de decisión en el algoritmo de Bosque aleatorio, a un 85%, se mantiene el problema de la sobrerrepresentación de la clase Otras Turberas, sin embargo disminuyen considerablemente las áreas clasificadas como tales, aumentando más aún las áreas sin clase.

Sobre la clase de Turberas Sphagnum e Impactadas, se obtiene el mejor resultado de todos los algoritmos de clasificación aquí presentados. Al comparar con imágenes de alta resolución en el software *Google Earth*, se observa una muy buena capacidad de clasificación en el área de estudio y por ende, se considera un modelo con una buena capacidad de generalización.

Finalmente, en la Figura 2.37, se puede observar la clasificación realizada mediante el algoritmo Bosque Aleatorio, con un umbral del 95%.

Mapeo en base a Bosque Aleatorio. Umbral 0,95
EPSG: 32718 WGS84 / UTM zona 18S

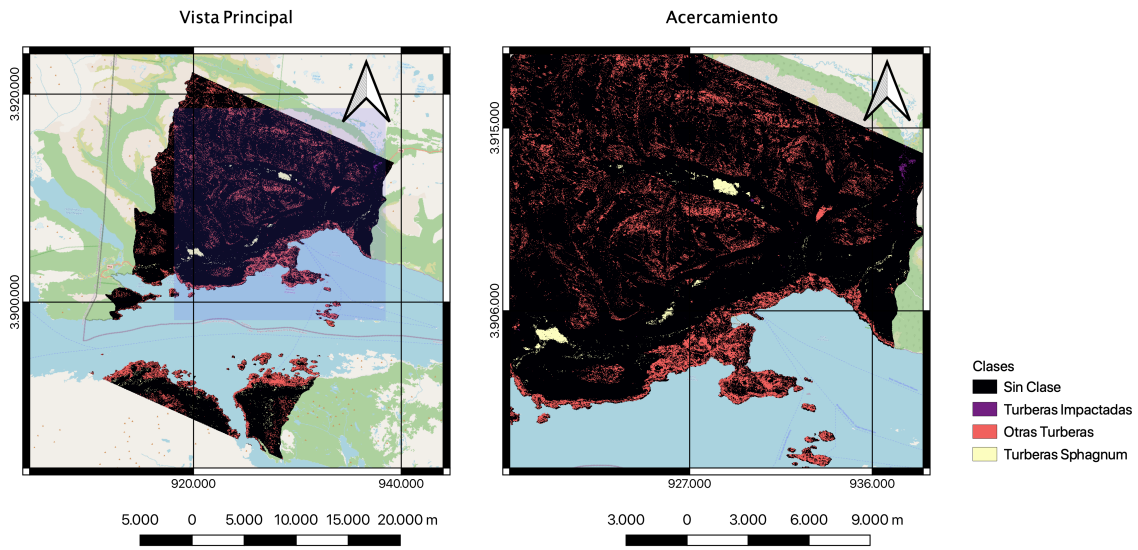


Figura 2.37: Clasificación en base a Bosque Aleatorio con umbral de 0.95 (Elaboración propia).

En este modelo, el problema de la sobrerrepresentación de la clase Otras Turberas disminuye prácticamente de manera total. Sin embargo, de todas maneras se observan clasificaciones de áreas que evidentemente no son turberas y se refuerza la idea de una clase muy heterogénea desde su etiquetado.

Para las clases Turberas Sphagnum e Impactadas, se observa una buena clasificación de los polígonos de entrenamiento, pero una pérdida de la capacidad de generalización del modelo.

2.6. Discusión

En la sección de Discusión del presente Trabajo de Título, se registra el desarrollo de las fases Comentarios y Discusión y planificación del ciclo de trabajo realizado.

La discusión se estructura según cada uno de los hitos descritos para dichas fases en sección de Diseño.

2.6.1. Fase Comentarios

En esta sección, se discute el desarrollo de la fase Comentarios, según cada uno de sus hitos.

2.6.1.1. Preprocesamiento y obtención de métricas

Lo primero que vale la pena mencionar, es que para todo el desarrollo del presente trabajo, se contó únicamente con un producto SAOCOM para una fecha dada de adquisición.

Esto no solo impacta únicamente la cantidad y tipo de polígonos de entrenamiento disponibles (seis de la clase Turberas Sphagnum, cinco de la clase Otras Turberas y tres de la clase Turberas Impactadas) y, por ende, la capacidad de generalización del modelo, sino que además, coarta el éxito del preprocesamiento.

Sobre el primer punto, vale la pena mencionar que el área descrita por el producto no se trata particularmente de una en donde abunde la presencia de turberas, como sí sucede en zonas aledañas. Esto dificulta tanto la identificación de ejemplos para las clases, como el análisis de la generalización de los modelos a toda la cobertura en cuestión. Además, de cara a la eventual generalización del modelo a una mayor extensión de territorio, sería útil contar con imágenes que presenten diversas condiciones topográficas para, así, desarrollar un conjunto de datos de entrenamiento lo suficientemente representativo del área de estudio.

La coartación del éxito del preprocesamiento, se debe a que la disponibilidad de productos de una misma área de estudio, pero con fechas de adquisición diferentes, permite una mucho mejor reducción del moteado en los mismo. Con la disponibilidad de un único producto, aún después de aplicado el filtro de moteado, el fenómeno persiste de manera evidente en los datos utilizados.

Finalmente, vale la pena reconocer en este punto, las limitaciones evidentes que tiene un proceso de etiquetado realizado únicamente mediante análisis visual de imágenes de alta resolución. La incorporación de datos in situ para la identificación de clases, podría jugar un rol fundamental en la mejora de los resultados aquí obtenidos.

2.6.1.2. Entrenamiento y métricas de desempeño

Como se comentó extensamente en la fase previa, las tres clases identificadas tienen diversos grados de heterogeneidad en términos del comportamiento de las métricas analizadas para cada uno de sus polígonos. En general, se observa que los polígonos de la clase Sphagnum e Impactadas tienen un comportamiento bastante más uniforme en las diversas métricas. Para

la clase Otras Turberas, la tónica en todas las métricas analizadas, fueron polígonos sin un comportamiento en común que permitiese diferenciarlos.

Se cree que esta se trata de una clase demasiado heterogénea, que incorpora diversas coberturas. Para efectos de la obtención de un mejor resultado, sería profundamente beneficiosa la separación de esta clase entre diversas coberturas de suelo más específicas. Nuevamente, la incorporación de datos in situ sería de suma relevancia para el objetivo mencionado.

Además, vale la pena destacar nuevamente el desbalance presente entre las clases. La clase Turberas Impactadas representa el 9,42 % de los píxeles etiquetados, la clase Otras Turberas el 26,69 % y la clase Turberas Sphagnum, el 63,89 % restante. Si bien es natural que exista este desbalance, se cree que incorporar más polígonos, en particular de la clase Turberas Impactadas, pudiese ser de suma utilidad para consolidar su clasificación exitosa.

Sobre el desempeño de cada uno de los modelos implementados, se observa que el Regresor Logístico es el más pobre de todos. En este caso, las métricas de Recuperación y Precisión muestran una clasificación apenas mejor que la asignación aleatoria de clases.

En el caso de los modelos Bosque Aleatorio y la Red Neuronal, el desempeño mejora sustantivamente, mostrando métricas aceptables, muy cercanas a uno.

Un punto importante de mencionar, es que en todos los algoritmos implementados, la clasificación se desagrega por píxeles individuales. Dicha decisión se toma considerando la simplicidad y economía en recursos computacionales que significaría una eventual ampliación de la herramienta a una mayor cobertura de territorio. Sin perjuicio de lo cual, explorar otro tipo de algoritmos de clasificación, que operen a mayor escala, como redes neuronales convolucionales, es una proyección natural de la investigación.

2.6.1.3. Ampliación al área de estudio

Uno de los puntos clave a discutir en esta parte, es la decisión de la incorporación del umbral como herramienta de determinación de píxeles con clase y sin clase.

Como ya se ha comentado anteriormente, es ideal la incorporación de una mayor variedad de polígonos de entrenamiento asociados a diversas coberturas de suelo, que permitan prescindir de esta herramienta. Esta podría ser, por ejemplo, la razón de un desempeño deficiente en el caso de la Red Neuronal. Sin embargo, su incorporación resulta útil para los objetivos de esta primera iteración del ciclo de trabajo y más aún, permite obtener, para el caso del modelo de Bosque Aleatorio, una clasificación bastante precisa, al menos de las clases Sphagnum e Impactadas.

Es importante destacar que, en cada uno de los modelos aquí tratados, se probaron diversos umbrales y se analizaron de manera visual los resultados que cada uno de ellos produjo. Los umbrales que se decidieron incorporar en cada modelo, dicen relación con la posibilidad de analizar el comportamiento de los clasificadores.

Además, es importante entender que los umbrales definidos para cada modelo no son en

absoluto comparables. La función de probabilidad de salida de cada uno de los modelos tiene su metodología propia de cálculo. Así pues, se seleccionan diversos umbrales según cada uno de los modelos implementados.

Al ampliar la clasificación a toda el área de estudio y comparar los resultados con visualización de imágenes de alta resolución, como ya se comentó anteriormente, en casi todos los casos se evidencia una sobrerrepresentación de la clase Otras Turberas. Esto refuerza la idea de una clase con problemas de etiquetado, que sería sumamente beneficioso subdividir en coberturas con un comportamiento más homogéneo a las diversas métricas de análisis.

Se refuerza, además, la necesidad de incorporar nuevas clases de coberturas de suelo, que permitan prescindir de la herramienta del umbral y mejorar la capacidad de generalización de cada uno de los modelos estudiados.

Sobre la capacidad de generalización de los modelos, es decir, su capacidad de mapear correctamente la extensión total del área de estudio, se observa que el algoritmo de Bosque aleatorio tiene el mejor desempeño, seguido por la Red Neuronal y finalmente el Regresor Logístico. En específico, se cree que la implementación del algoritmo de Bosque aleatorio con un umbral de 85 % produce el mejor resultado de todos, con un mapeo bastante preciso de las clases Turberas Sphagnum e Impactadas en la zona.

Se cree que una de las grandes ventajas que este modelo tiene sobre los otros, es la selección aleatoria de métricas con las cuales construir los árboles de decisión. Esto se evidencia al observar el ranking de características del algoritmo, que muestra importancias bastante disímiles entre las diversas métricas.

2.6.2. Fase Discusión y planificación

Finalmente, en esta sección, se discute el desarrollo de la fase Discusión y planificación, según cada uno de sus hitos.

2.6.2.1. Evaluación de la aplicabilidad en instrumentos de gestión del cambio climático.

Es importante entender las limitaciones del trabajo aquí realizado, que si bien permiten materializar el ejercicio de clasificación, se requiere de un análisis un poco más profundo en la definición de las clases madre Turberas gestionadas y no gestionadas para poder asegurar su utilización en instrumentos nacionales de gestión del cambio climático. Lo anterior, pues es evidente que las clases identificadas en cada uno de los modelos (Sphagnum, Otras e Impactadas) corresponden a un subconjunto y no al grupo completo de las clases madre Turberas gestionadas y Turberas no gestionadas.

Como ya se comentó anteriormente, según el IPCC, una turbera gestionada, es aquella en donde se han aplicado prácticas para la realización de actividades de producción, ecológicas o sociales [3]. Aquello es difícilmente evidenciable con la utilización únicamente del análisis polarimétrico aquí expuesto. Un análisis de este tipo por sí solo, como el realizado en el presente trabajo, no permite, por ejemplo, descartar de plano que una turbera donde no se evidencia una actividad extractiva, sea una turbera no-gestionada. Esto pues, por ejemplo,

no puede juzgar, sobre la ocurrencia de actividades ecológicas o sociales en ella.

Se cree que el insumo generado, si bien no permite diferenciar de manera absoluta las Turberas gestionadas de aquellas no gestionadas, entrega un resultado de altísima riqueza para dichos fines.

2.6.2.2. Evaluación de la contribución a la protección

El solo hecho de mapear un ecosistema e identificarlo en el territorio, es el punto de partida para una protección efectiva del mismo. Este trabajo surge de una necesidad de identificación que es una deuda pendiente del país (Chile). Así, incluso, está expuesto en su Contribución nacionalmente determinada, discutida con anterioridad.

Por ende se considera que el mapeo aquí realizado contribuye fuertemente a una protección del ecosistema, tanto en el territorio chileno como argentino.

Cabe destacar, que el trabajo aquí realizado corresponde a una primera iteración de un ciclo de trabajo que pretende generalizar la herramienta a una mayor cobertura de territorio. Desde ya, el mapeo alcanza una contribución en términos de la protección que permite, pero evidentemente, su alcance será mayor de desarrollarse las siguientes etapas.

Desde otro punto de vista, el mapeo implementado permite identificar claramente el desarrollo de una actividad extractiva, lo cual puede facilitar la definición de focos de fiscalización. Esto también es una contribución relevante hacia la protección de un ecosistema particularmente amenazado por este tipo de actividades.

2.6.2.3. Evaluación del uso de datos polarimétricos

Con todo, se evidencia el poder del uso de datos polarimétricos para el mapeo de turberas en la Patagonia chileno argentina.

Si bien se identifican variadas áreas de mejora para la herramienta desarrollada, lo cierto es que se comprueba que el uso de datos totalmente polarimétricos (SAOCOM de banda L) permite un mapeo efectivo del objeto de estudio. Esto es un punto clave a la hora de proyectar nuevas etapas de desarrollo, pues, como ya se ha comentado en reiteradas ocasiones, posee beneficios sustanciales respecto del uso de otros productos (ópticos), en condiciones climáticas adversas como las de la Patagonia.

De cara a las etapas de ampliación de la herramienta en el territorio, el uso de datos polarimétricos no solo simplifica la implementación, sino que, además, reduce los costos computacionales de la misma y, eventualmente, estandariza los tiempos de producción de adquisiciones válidas.

2.6.2.4. Discusión orientada a la generalización

En una segunda etapa de desarrollo del presente trabajo, se proyecta la generalización del resultado obtenido a una mayor cobertura de territorio, incorporando los aprendizajes aquí

obtenidos.

Para ello y según lo analizado previamente, se deben tomar en cuenta las siguientes consideraciones:

- Elección de áreas de estudio ricas en turberas y de las que, en el mejor de los casos, se cuente con levantamientos de datos in situ sobre la distribución geográfica de las mismas.
- Elección de áreas de estudio de condiciones topográficas diferentes.
- Disposición de al menos dos productos por cada área estudio, con fechas de adquisición ligeramente distintas.
- Definición e identificación de nuevas clases de coberturas de suelo fuera de las turberas, que permitan una clasificación completa.

Capítulo 3

Conclusiones

El objetivo de este Trabajo de Título ha sido desarrollar una herramienta para el reconocimiento de turberas en la Patagonia chileno argentina, que facilite la protección del ecosistema y se convierta en un insumo para instrumentos de gestión del cambio climático.

En un primer ciclo de desarrollo del trabajo y aún cuando se reconocen las limitaciones de la herramienta generada, se cree que el objetivo se cumple a cabalidad. En este, se contribuye con un mapeo preliminarmente exitoso del área de estudio, en términos de tres clases: Turberas Sphagnum, Turberas Impactadas y Otras Turberas. Cada una de ellas, se identifica dentro de las categorías contempladas en las directrices del IPCC para la confección de inventarios nacionales de gases de efecto invernadero: Tierras gestionadas y no gestionadas.

Se implementan tres algoritmos de clasificación supervisada: Regresor Logístico, Red Neuronal y Bosque Aleatorio y se analizan los resultados obtenidos en cada uno de ellos. El algoritmo de Red Neuronal junto con el de Bosque Aleatorio, alcanzan macro-métricas Acierto, Precisión y Recuperación exitosas, de 0,98 y 1,00, respectivamente.

El último de ellos, además, es aquel que presenta una mejor capacidad de generalización. Al comparar los resultados obtenidos de éste con imágenes satelitales de alta resolución, se observa una clasificación exitosa de las clases Turberas Sphagnum y Turberas Impactadas y una leve sobrerrepresentación de la clase Otras Turberas, cuya génesis se encuentra en un etiquetado perfectible.

Una de las principales limitaciones del trabajo se relaciona con la cantidad de coberturas de suelo mapeadas. Hacia futuras implementaciones de la herramienta, incorporar nuevas coberturas de suelo que no correspondan a turberas, así como profundizar en la descripción de la clase Otras Turberas, pudiese permitir mejorar de manera sustantiva la capacidad de generalización del modelo. Además, se sugiere explorar la implementación de otros algoritmos de clasificación supervisada, como redes neuronales convolucionales.

Se reafirma mediante el presente trabajo, el potencial que tienen los productos SAOCOM de banda L para conseguir los fines deseados, perfilándose como un recurso tremendamente valioso para la identificación y, por qué no, el monitoreo de turberas en latitudes extremas y/o climas desfavorables.

De la mano con lo anterior, se espera que el presente trabajo sirva para justificar la solicitud de accesibilidad a más productos de la misma naturaleza y, por ende, en un segundo ciclo de desarrollo, permita un alcance mayor a la herramienta, tanto en términos físicos como respecto al impacto y gracia que su uso pueda traer.

Se cree, además, que el presente trabajo cobra un valor especial al surgir de una instancia de colaboración bilateral, que refuerza el sentido de unidad en la lucha contra un fenómeno que no reconoce fronteras.

Si bien queda un largo camino por recorrer, lo realizado hasta el momento ha servido profundamente en la concepción holística del problema. Algo esencial para la salud del trabajo y para la materialización efectiva del mismo en un aporte real y aunque pequeño, tangible para nuestra sociedad.

Bibliografía

- [1] Domínguez, E. y Vega-Valdés, D., Funciones y servicios ecosistémicos de las turberas en Magallanes. Punta Arenas, Chile: Instituto de Investigaciones Agropecuarias, 2015.
- [2] Edward, B. y Barbier, J., Economics of Peatlands Conservation, Restoration, and Sustainable Management - A Policy Report for the Global Peatlands Initiative. Nairobi, Kenia: United Nations Environment Programme, 2021.
- [3] Eggleston, H. *et al.*, 2006 IPCC Guidelines for National Greenhouse Gas Inventories. Japón: IGES, 2006.
- [4] COP7, “Protocolo de Kyoto de la Convención Marco de las Naciones Unidas sobre el Cambio Climático,” (Kyoto, Japón), Naciones Unidas, 1997.
- [5] “Ley n° 21455.” Diario Oficial de la República de Chile, 2022.
- [6] IPCC, “Principles governing IPCC work,” (Vienna, Italia), Naciones Unidas, 1998.
- [7] Abram, N. *et al.*, IPCC Special Report on the Ocean and Cryosphere in a Changing Climate, cap. Framing and Context of the Report, p. 73–129. Cambridge, UK y New York, US: IPCC, 2019.
- [8] Masson-Delmotte, V. *et al.*, The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, cap. Summary for Policymakers, pp. 3–32. Cambridge, UK y New York, US: IPCC, 2021.
- [9] Gobierno de Chile, “Contribución determinada a nivel nacional (NDC) de Chile, Actualización 2020,” 2020.
- [10] COP21, “Acuerdo de París de la Convención Marco de las Naciones Unidas sobre el Cambio Climático,” (París, Francia), UNFCCC, 2015.
- [11] Aravena, C. *et al.*, “Boletín n° 12.017-12,” 2018.
- [12] Moore, T. y Basiliko, N., “Decomposition in boreal peatlands.,” Springer, pp. 125–144, 1996.
- [13] Martínez, A. *et al.*, Bases ecológicas preliminares para la conservación de los tipos de hábitat de interés comunitario en España. Madrid, España: Ministerio de Medio Ambiente, y Medio Rural y Marino, 2009.
- [14] Yu, Z. *et al.*, “Global peatland dynamics since the last glacial maximum.,” Geophysical Research Letters, 2010.
- [15] Iturraspe, R., Las turberas de Tierra del Fuego y el cambio climático global. Buenos Aires, Argentina: Fundación para la Conservación y el Uso Sustentable de los Humedales, 2010.

- [16] Parish, F. *et al.*, Assessment on peatlands, biodiversity and climate change. Global Environment Center, Kuala Lumpur and Wetlands International Wageningen, 2008.
- [17] NASA Applied Remote Sensing Training Program (ARSET), “Mapeo de cultivos y sus características biofísicas con sar polarimétrico y teledetección Óptica,” 2022.
- [18] Cloude, S. y Pottier, E., “A review of target decomposition theorems in radar polarimetry,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 34, no. 2, pp. 498–518, 1996.
- [19] Fernandez, Y. y Soria-Ruiz, J., *Imágenes SAR y Conceptos Básicos de Polarimetría*, pp. 37–66. 2015.
- [20] Agashe, S., *Polarimetric Decomposition of SAR Data for Forest Structure Assessment*. Göteborg, Suiza: Department of Earth and Space Sciences, CHALMERS UNIVERSITY OF TECHNOLOGY, 2013.
- [21] Jong-Sen, L. y Pottier, E., *Polarimetric Radar Imaging: From Basics to Applications*. 2009, [doi:10.1201/9781420054989](https://doi.org/10.1201/9781420054989).
- [22] Cloude, S., Pottier, E., y Boerner, W., “Unsupervised image classification using the entropy/alpha/anisotropy method in radar polarimetry,” 2002.
- [23] Touzi, R., “Target scattering decomposition in terms of roll-invariant target parameters,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 1, 2007.
- [24] Ruiz, J. y Doberti, M., *Catastro y Caracterización de los Turbales de Magallanes*. Punta Arenas, Chile: Consultora Ruiz y Doberti Ltda, 2005.
- [25] “Misiones Satelitales, SAOCOM, Características técnicas.” <https://www.argentina.gob.ar/ciencia/conae/misiones-espaciales/saocom/caracteristicas-tecnicas>. Visitado: 16-11-2022.
- [26] Touzi, R., “Phase of target scattering for wetland characterization using polarimetric c-band sar,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 9, p. 3241–3261, 2009.
- [27] Miranda, A., “Análisis de imágenes de alta resolución en el área de estudio.” reunión privada, 2022.
- [28] Jong-Sen, L. *et al.*, “Improved sigma filter for speckle filtering of sar imagery,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 1, pp. 202–213, 2009.
- [29] GDAL/OGR contributors, *GDAL/OGR Geospatial Data Abstraction software Library*. Open Source Geospatial Foundation, 2020.
- [30] Small, D. y Schubert, A., *Guide to ASAR Geocoding*. Zurich, Suiza: Remote Sensing Laboratories, University of Zurich, 2008.
- [31] Waskom, M. L., “seaborn: statistical data visualization,” *Journal of Open Source Software*, vol. 6, no. 60, p. 3021, 2021, <https://doi.org/10.21105/joss.03021>.
- [32] McKinney, W., “Data Structures for Statistical Computing in Python,” en *Proceedings of the 9th Python in Science Conference (Stéfan van der Walt y Jarrod Millman, eds.)*, pp. 56 – 61, 2010, [doi:10.25080/Majora-92bf1922-00a](https://doi.org/10.25080/Majora-92bf1922-00a).
- [33] Pedregosa, F. *et al.*, “Scikit-learn: Machine learning in python,” *Journal of machine learning research*, vol. 12, pp. 2825–2830, 2011.

- [34] Abadi, M. *et al.*, “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems,” 2015, <https://www.tensorflow.org/>. Software available from tensorflow.org.

Anexos

Anexo A. Exploración en detalle de métricas

En el presente Anexo A, se detallan todos los gráficos de visualización producidos por cada métrica de estudio. Los gráficos de la métrica “Entopía” no se presentan, por ya haber sido tratados previamente, en la sección de Resultados.

A.1. Anisotropía

A.1.1. Mapas de Calor

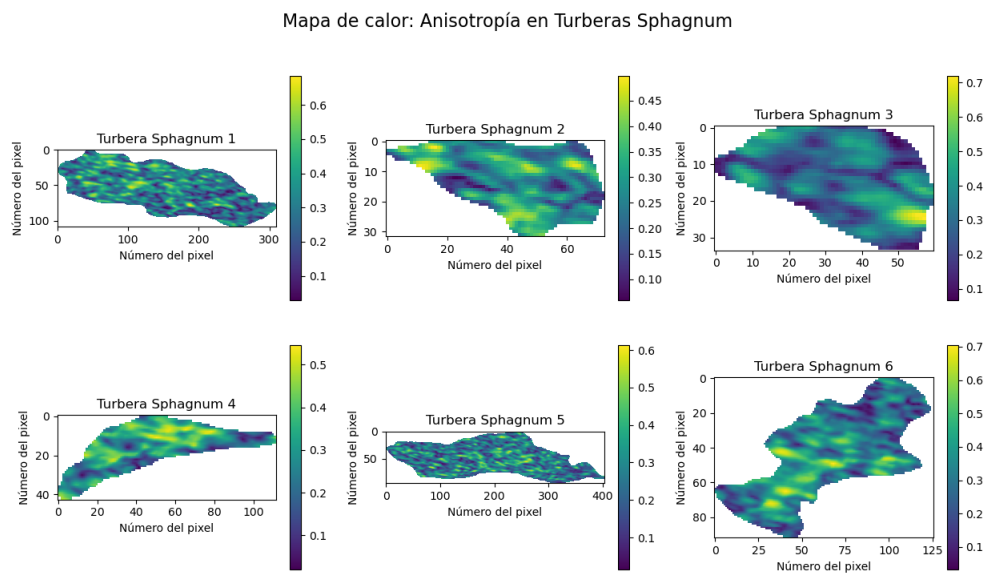


Figura A.1: Mapa de calor de Anisotropía para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Anisotropía en Otras Turberas

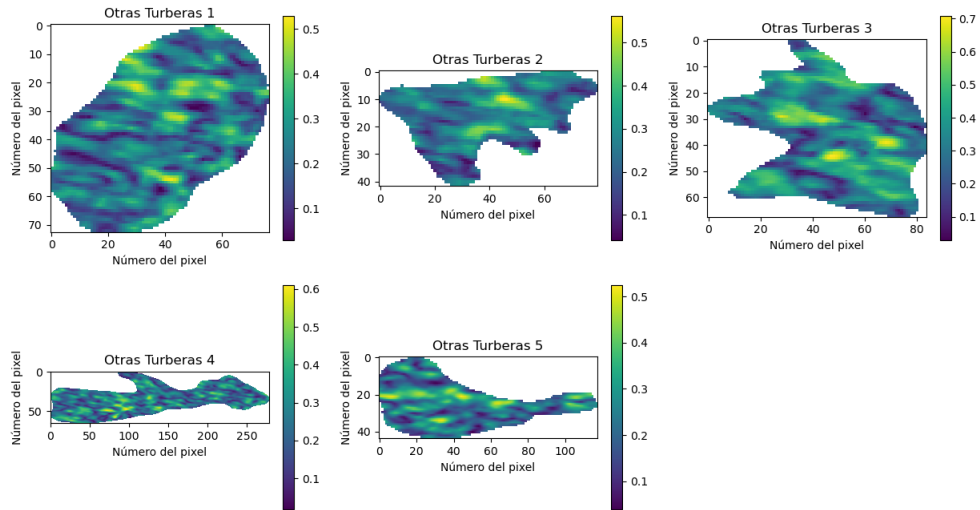


Figura A.2: Mapa de calor de Anisotropía para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Anisotropía en Turberas Impactadas




Figura A.3: Mapa de calor de Anisotropía para polígonos de “Turberas Impactadas” (Elaboración propia).

A.1.2. Funciones densidad de probabilidad

Histogramas de Anisotropía en Otras Turberas (individuales)

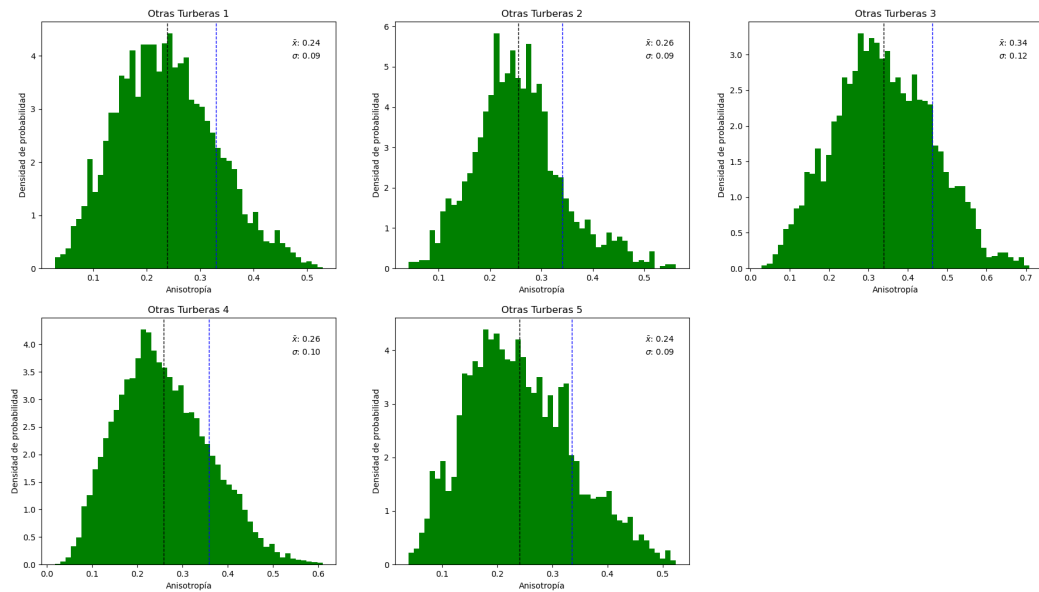


Figura A.4: Función densidad de probabilidad de Anisotropía en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Anisotropía en Turberas Sphagnum (individuales)

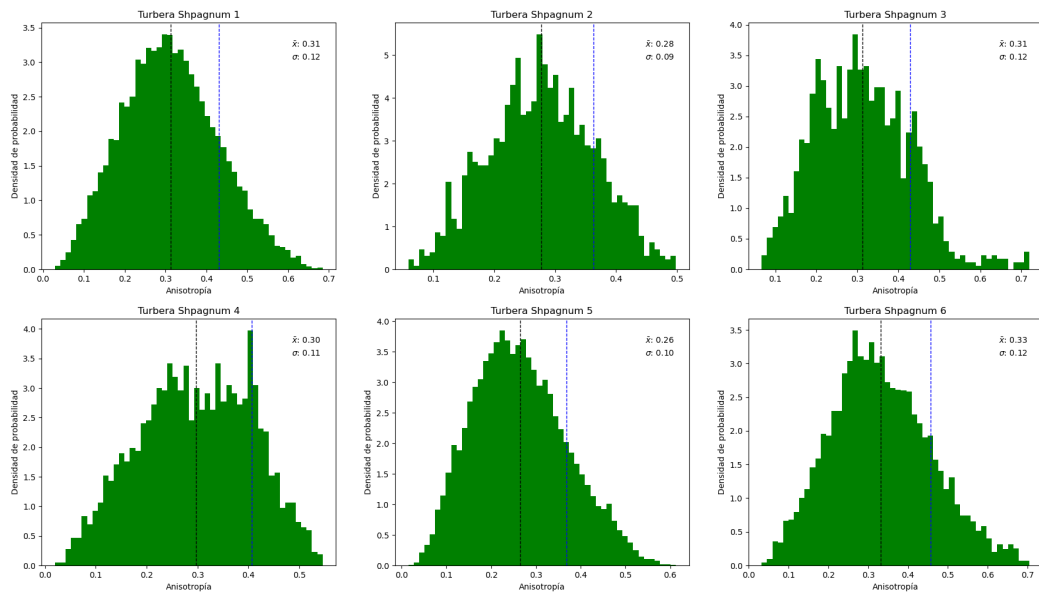


Figura A.5: Función densidad de probabilidad de Anisotropía en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Anisotropía en Turberas Impactadas (individuales)




Figura A.6: Función densidad de probabilidad de Anisotropía en polígonos de “Turberas Impactadas” (Elaboración propia).

A.1.3. Agrupados

Anisotropía agrupada por clase (método KDE)




Figura A.7: Anisotropía agrupada por clase (Elaboración propia).

A.1.4. Resumen

Comparativa general de Anisotropía en turberas (método KDE)




Figura A.8: Anisotropía: Gráfico resumen (Elaboración propia).

A.2. Alfa

A.2.1. Mapas de Calor

Mapa de calor: Alfa en Turberas Sphagnum

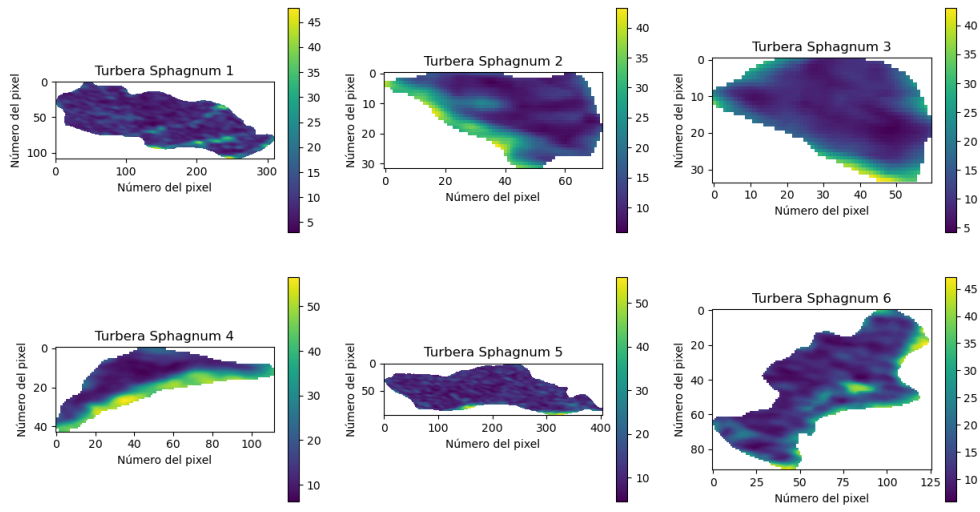


Figura A.9: Mapa de calor de Alfa para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Alfa en Otras Turberas

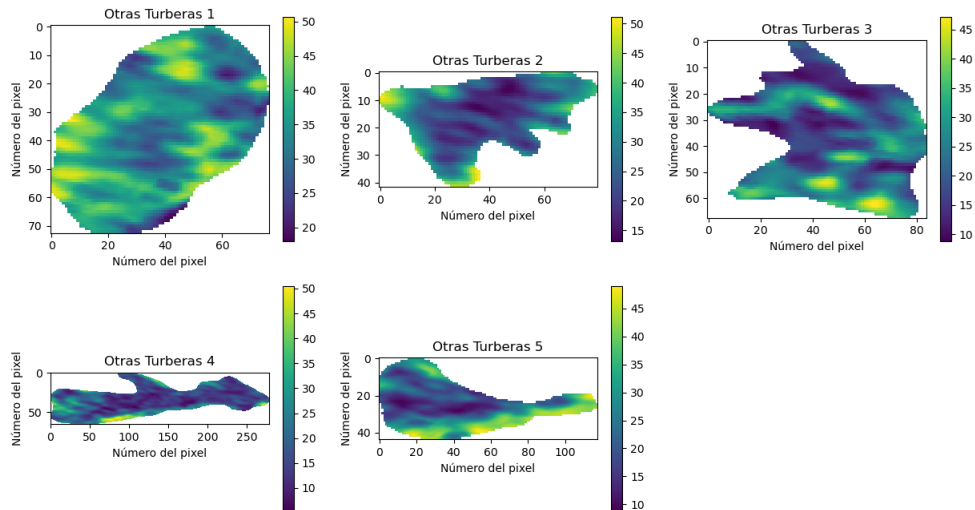


Figura A.10: Mapa de calor de Alfa para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Alfa en Turberas Impactadas




Figura A.11: Mapa de calor de Alfa para polígonos de “Turberas Impactadas” (Elaboración propia).

A.2.2. Funciones densidad de probabilidad

Histogramas de Alfa en Otras Turberas (individuales)

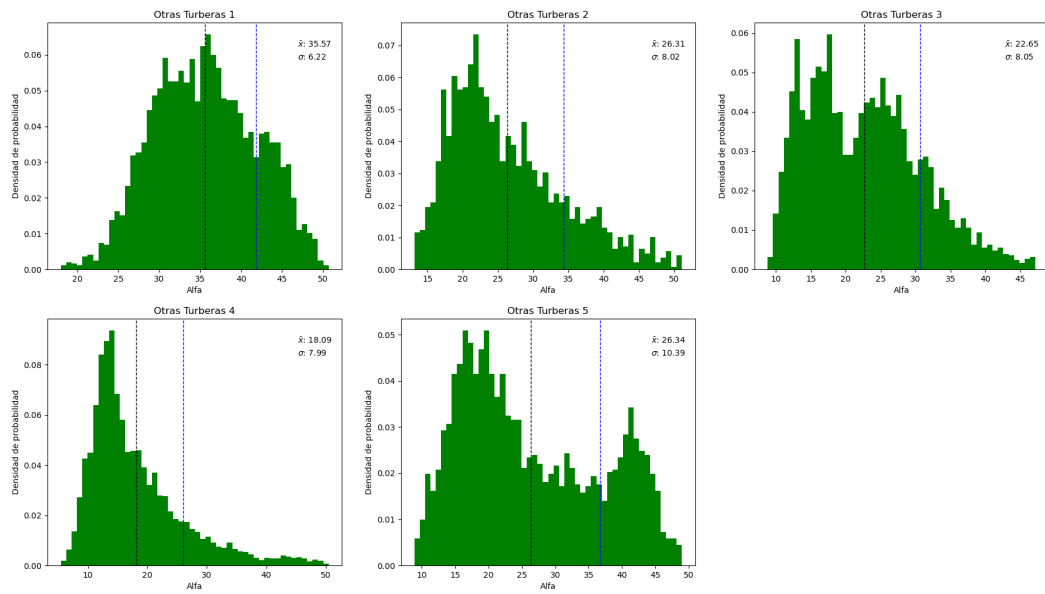


Figura A.12: Función densidad de probabilidad de Alfa en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Alfa en Turberas Sphagnum (individuales)

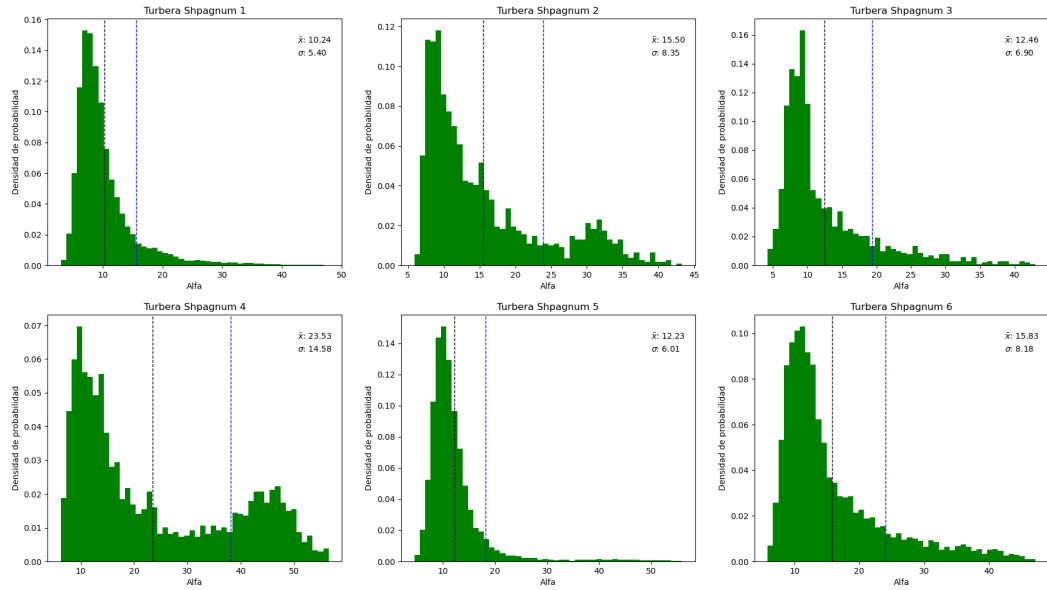


Figura A.13: Función densidad de probabilidad de Alfa en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Alfa en Turberas Impactadas (individuales)




Figura A.14: Función densidad de probabilidad de Alfa en polígonos de “Turberas Impactadas” (Elaboración propia).

A.2.3. Agrupados

Alfa agrupada por clase (método KDE)




Figura A.15: Alfa agrupada por clase (Elaboración propia).

A.2.4. Resumen




Figura A.16: Alfa: Gráfico resumen (Elaboración propia).

A.3. Superficie

A.3.1. Mapas de Calor

Mapa de calor: Superficie en Turberas Sphagnum

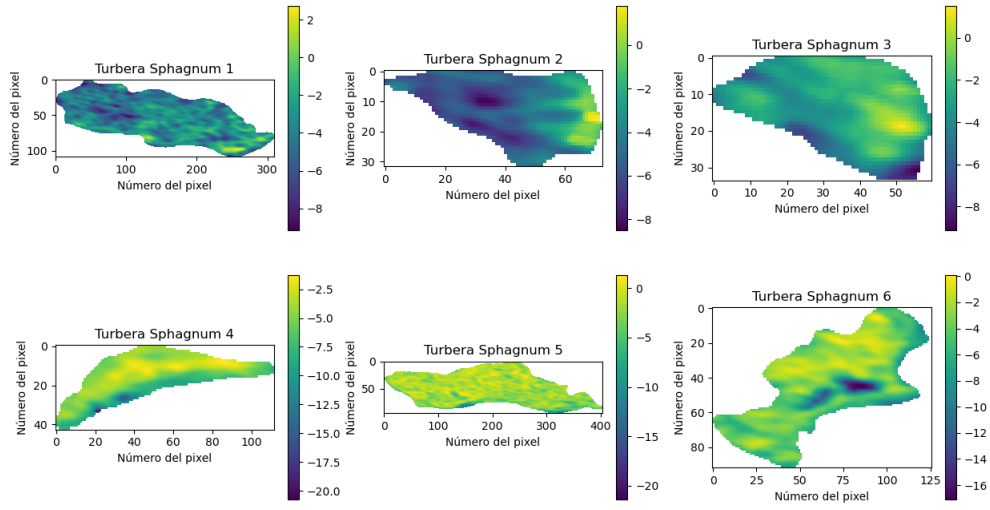


Figura A.17: Mapa de calor de Superficie para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Superficie en Otras Turberas

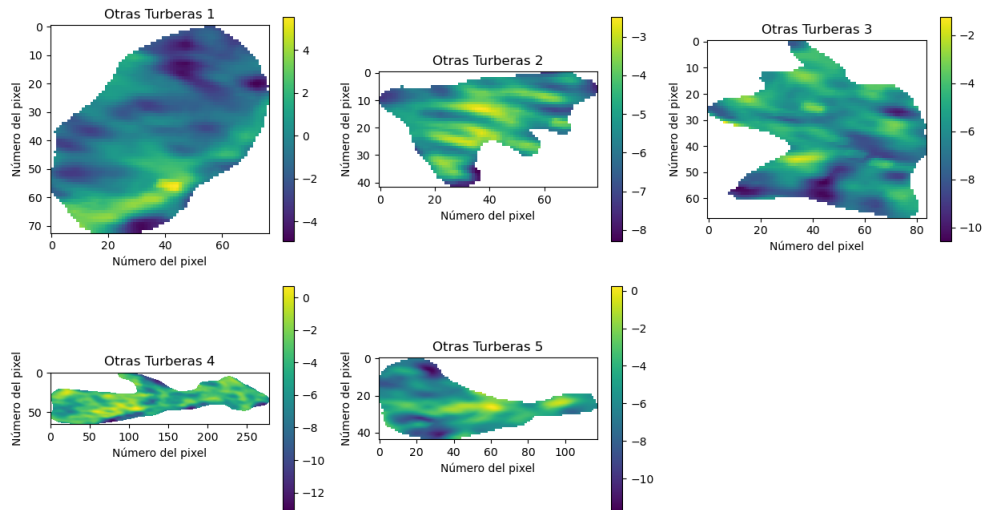


Figura A.18: Mapa de calor de Superficie para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Superficie en Turberas Impactadas




Figura A.19: Mapa de calor de Superficie para polígonos de “Turberas Impactadas” (Elaboración propia).

A.3.2. Funciones densidad de probabilidad

Histogramas de Superficie en Otras Turberas (individuales)

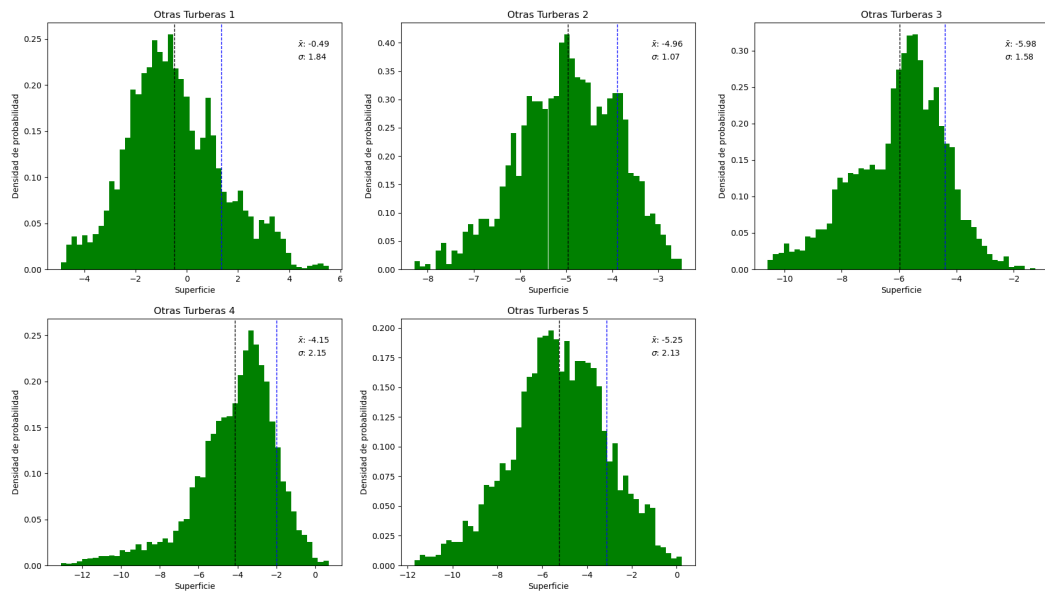


Figura A.20: Función densidad de probabilidad de Superficie en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Superficie en Turberas Sphagnum (individuales)

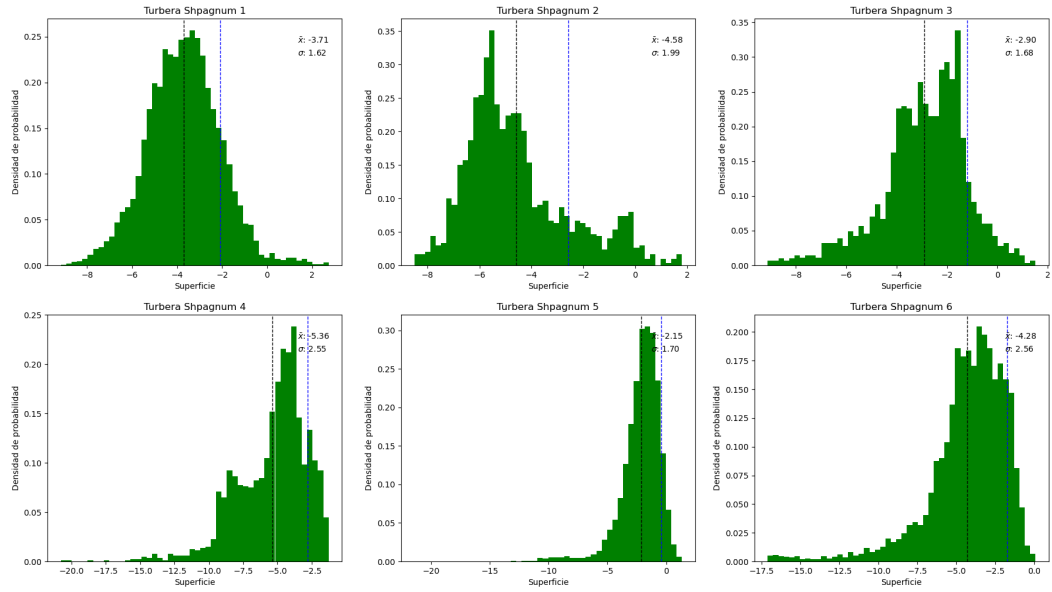


Figura A.21: Función densidad de probabilidad de Superficie en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Superficie en Turberas Impactadas (individuales)




Figura A.22: Función densidad de probabilidad de Superficie en polígonos de “Turberas Impactadas” (Elaboración propia).

A.3.3. Agrupados

Superficie agrupada por clase (método KDE)




Figura A.23: Superficie agrupada por clase (Elaboración propia).

A.3.4. Resumen




Figura A.24: Superficie : Gráfico resumen (Elaboración propia).

A.4. Volumen

A.4.1. Mapas de Calor

Mapa de calor: Volumen en Turberas Sphagnum

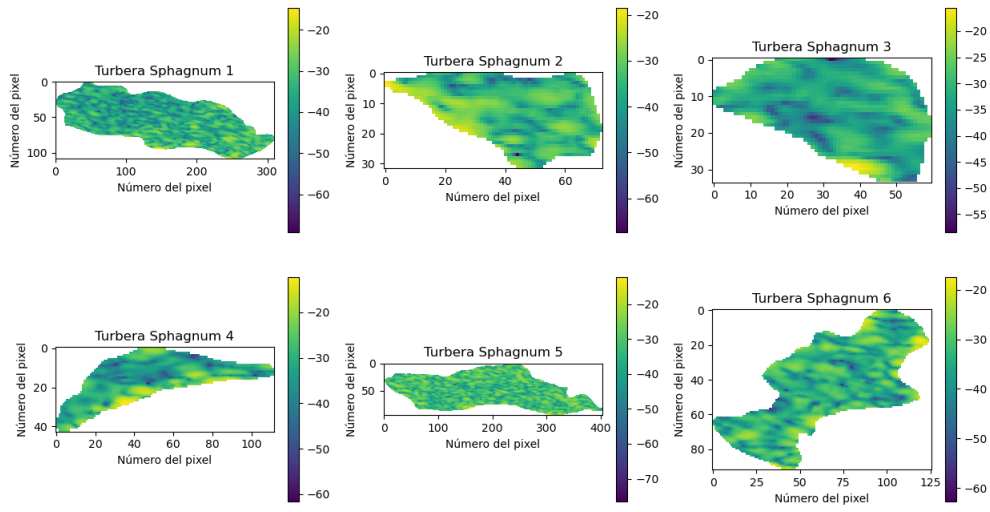


Figura A.25: Mapa de calor de Volumen para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Volumen en Otras Turberas

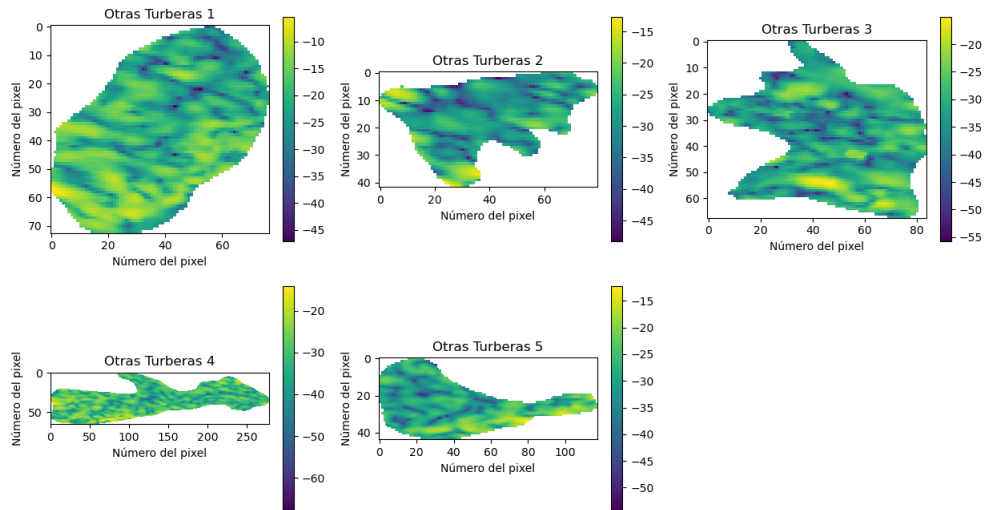


Figura A.26: Mapa de calor de Volumen para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Volumen en Turberas Impactadas




Figura A.27: Mapa de calor de Volumen para polígonos de “Turberas Impactadas” (Elaboración propia).

A.4.2. Funciones densidad de probabilidad

Histogramas de Volumen en Otras Turberas (individuales)

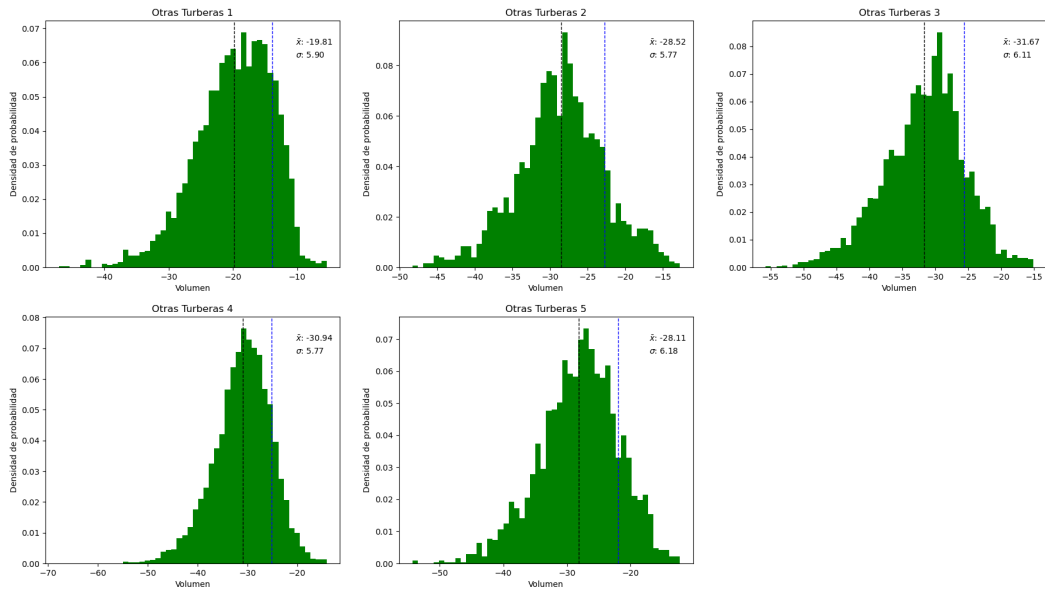


Figura A.28: Función densidad de probabilidad de Volumen en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Volumen en Turberas Sphagnum (individuales)

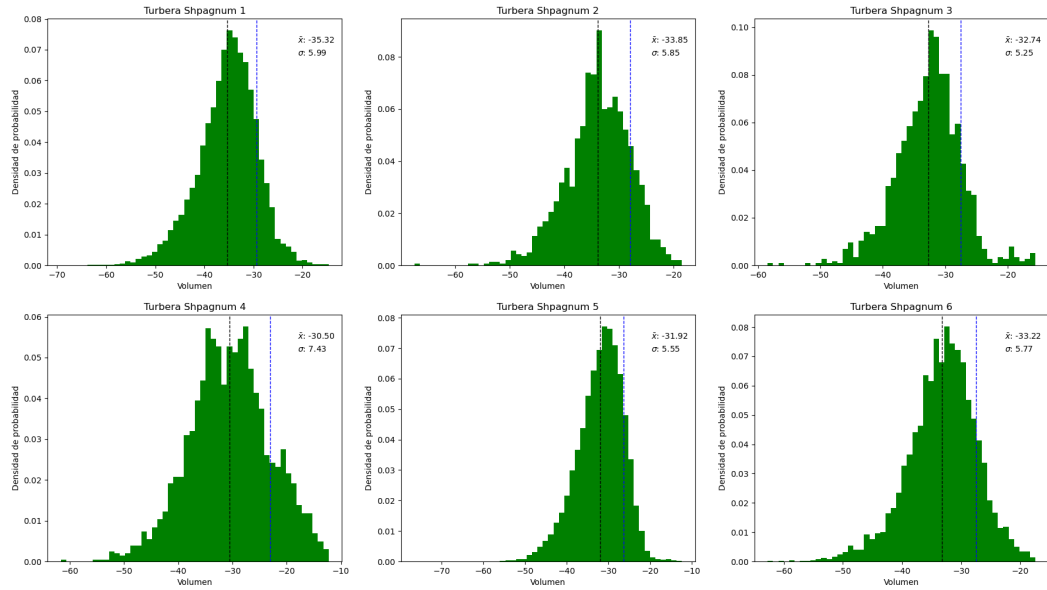


Figura A.29: Función densidad de probabilidad de Volumen en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Volumen en Turberas Impactadas (individuales)




Figura A.30: Función densidad de probabilidad de Volumen en polígonos de “Turberas Impactadas” (Elaboración propia).

A.4.3. Agrupados

Volumen agrupada por clase (método KDE)




Figura A.31: Volumen agrupado por clase (Elaboración propia).

A.4.4. Resumen




Figura A.32: Volumen : Gráfico resumen (Elaboración propia).

A.5. Doble Rebote

A.5.1. Mapas de Calor

Mapa de calor: Doble Rebote en Turberas Sphagnum

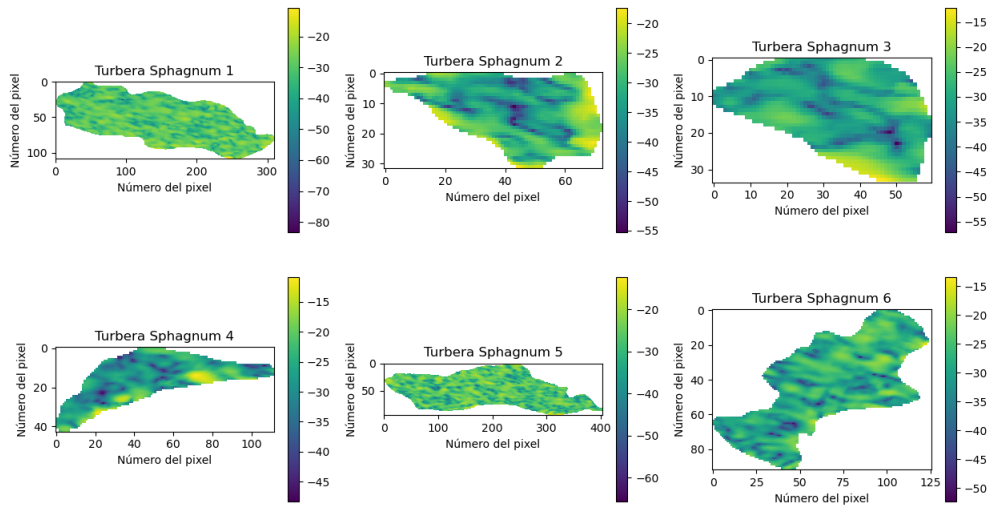


Figura A.33: Mapa de calor de Doble rebote para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Doble Rebote en Otras Turberas

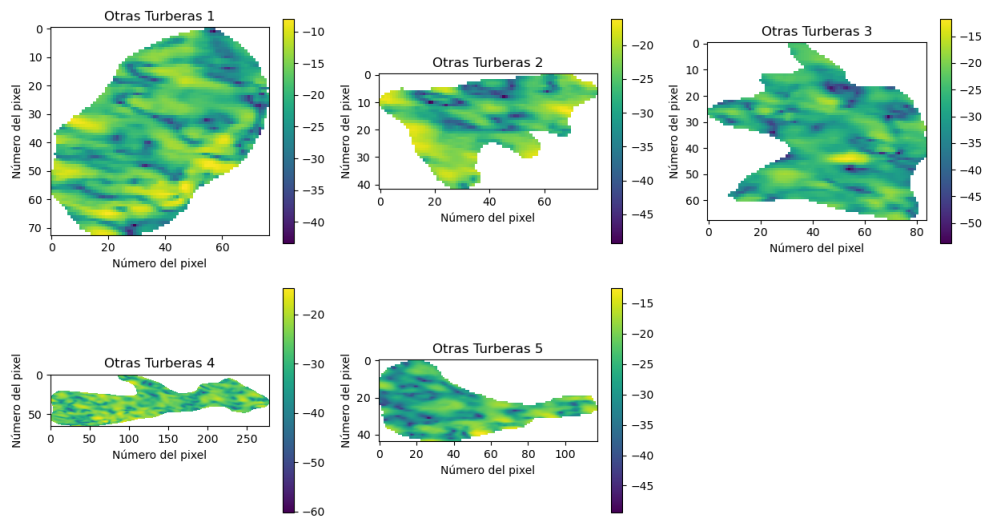


Figura A.34: Mapa de calor de Doble rebote para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Doble Rebote en Turberas Impactadas




Figura A.35: Mapa de calor de Doble rebote para polígonos de “Turberas Impactadas” (Elaboración propia).

A.5.2. Funciones densidad de probabilidad

Histogramas de Doble Rebote en Otras Turberas (individuales)

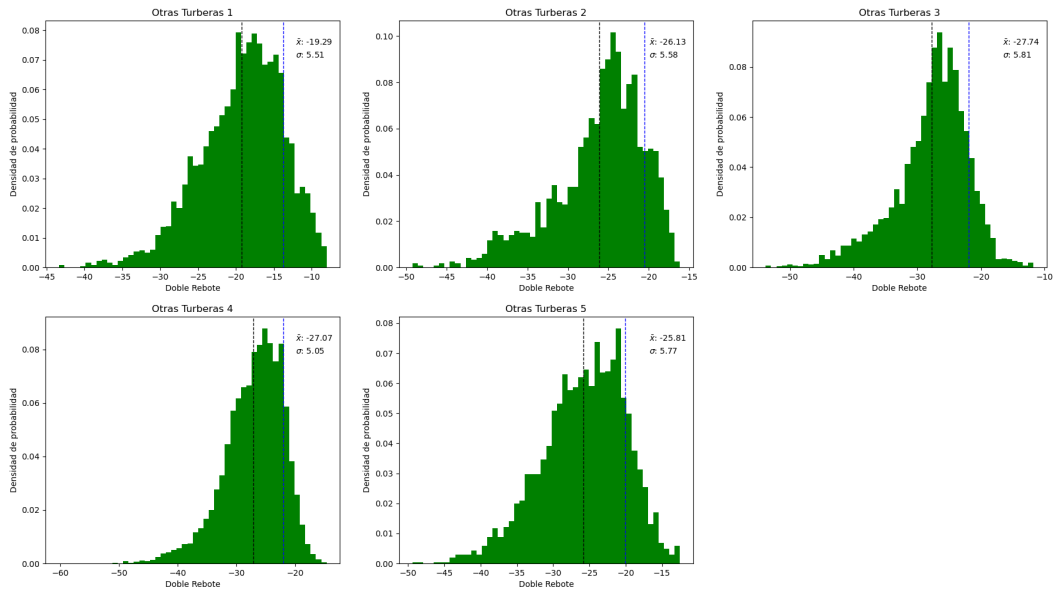


Figura A.36: Función densidad de probabilidad de Doble rebote en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Doble Rebote en Turberas Sphagnum (individuales)

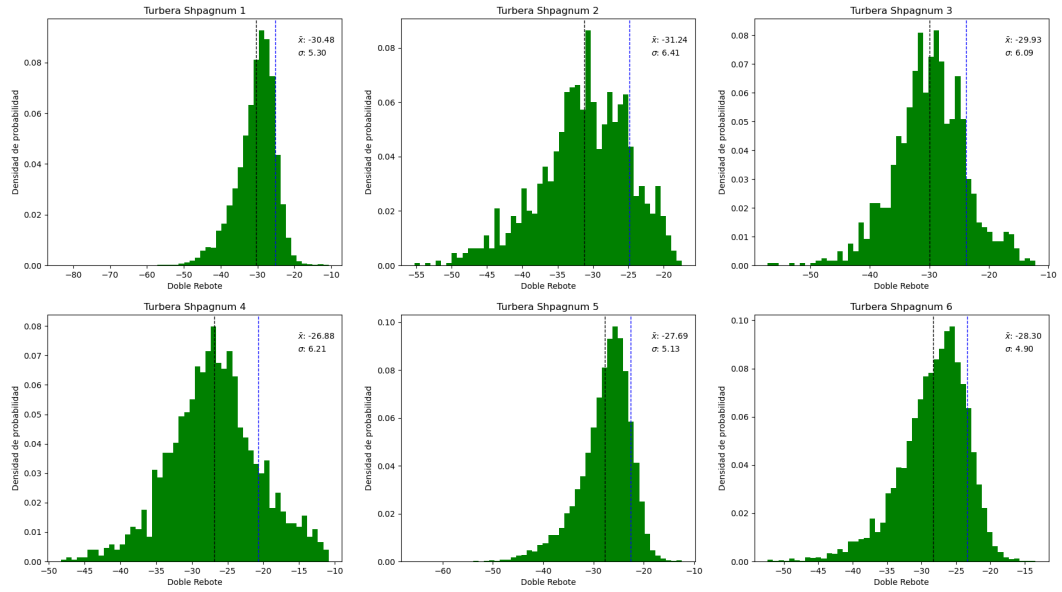


Figura A.37: Función densidad de probabilidad de Doble rebote en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Doble Rebote en Turberas Impactadas (individuales)




Figura A.38: Función densidad de probabilidad de Doble rebote en polígonos de “Turberas Impactadas” (Elaboración propia).

A.5.3. Agrupados

Doble Rebote agrupada por clase (método KDE)




Figura A.39: Doble rebote agrupado por clase (Elaboración propia).

A.5.4. Resumen




Figura A.40: Doble rebote : Gráfico resumen (Elaboración propia).

A.6. Phi

A.6.1. Mapas de Calor

Mapa de calor: Phi en Turberas Sphagnum

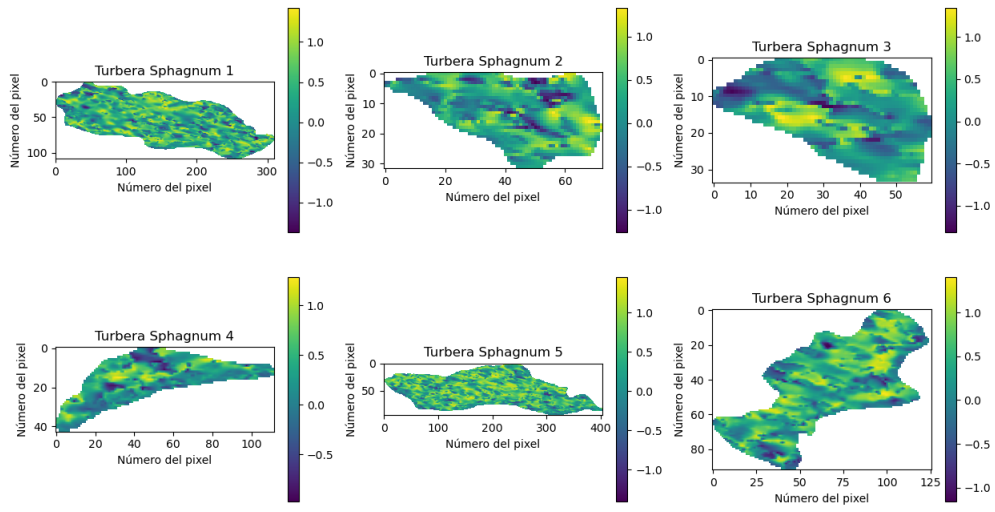


Figura A.41: Mapa de calor de Phi para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Phi en Otras Turberas

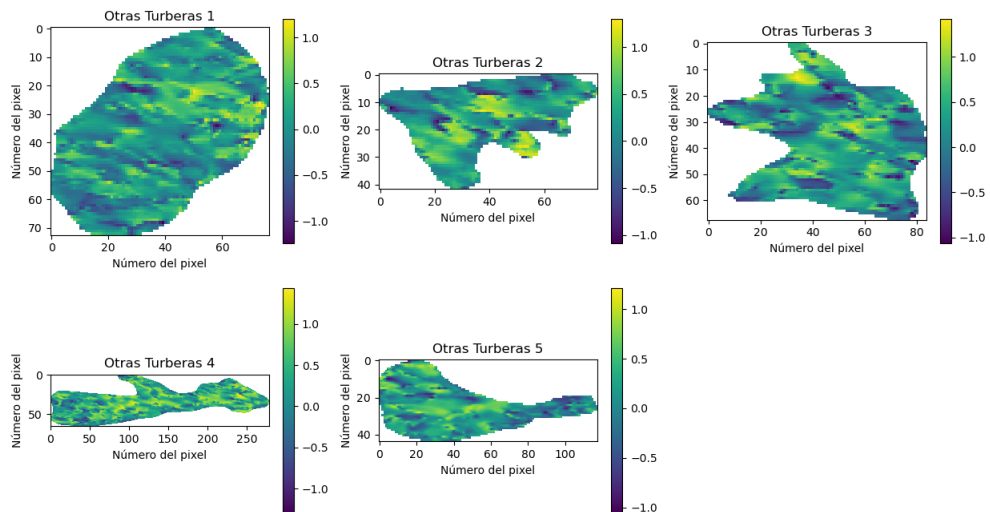


Figura A.42: Mapa de calor de Phi para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Phi en Turberas Impactadas




Figura A.43: Mapa de calor de Phi para polígonos de “Turberas Impactadas” (Elaboración propia).

A.6.2. Funciones densidad de probabilidad

Histogramas de Phi en Otras Turberas (individuales)

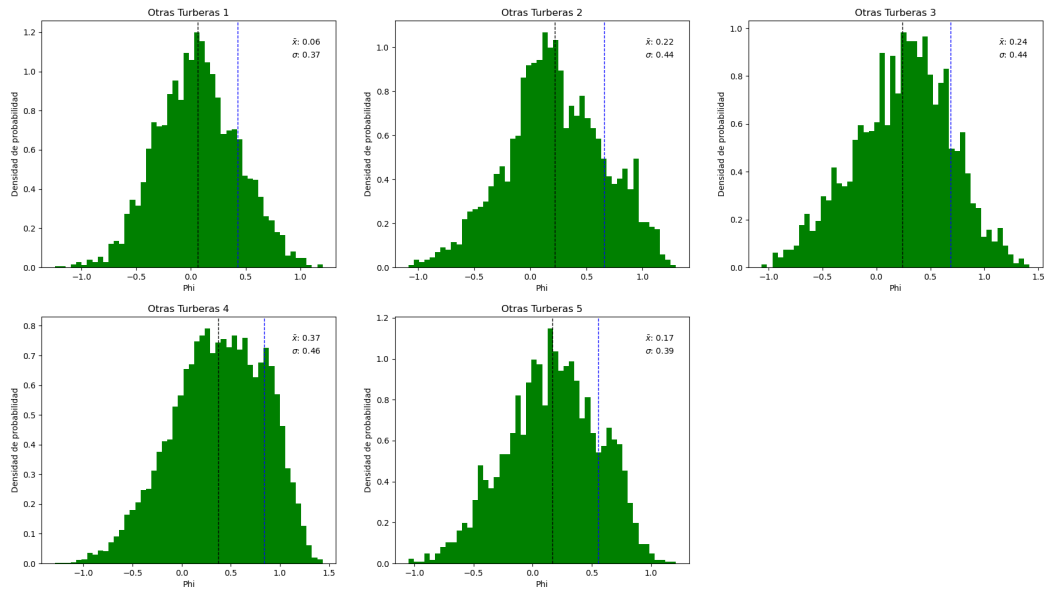


Figura A.44: Función densidad de probabilidad de Phi en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Phi en Turberas Sphagnum (individuales)

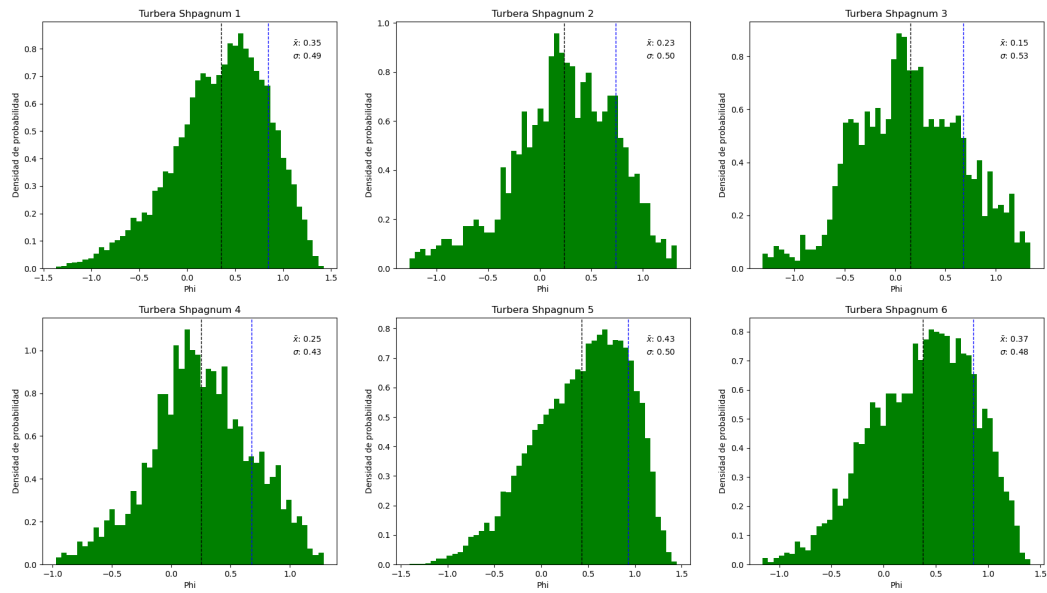


Figura A.45: Función densidad de probabilidad de Phi en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Phi en Turberas Impactadas (individuales)




Figura A.46: Función densidad de probabilidad de Phi en polígonos de “Turberas Impactadas” (Elaboración propia).

A.6.3. Agrupados

Phi agrupada por clase (método KDE)




Figura A.47: Phi agrupada por clase (Elaboración propia).

A.6.4. Resumen




Figura A.48: Phi: Gráfico resumen (Elaboración propia).

A.7. Elevación

A.7.1. Mapas de Calor

Mapa de calor: Elevación [m] en Turberas Sphagnum

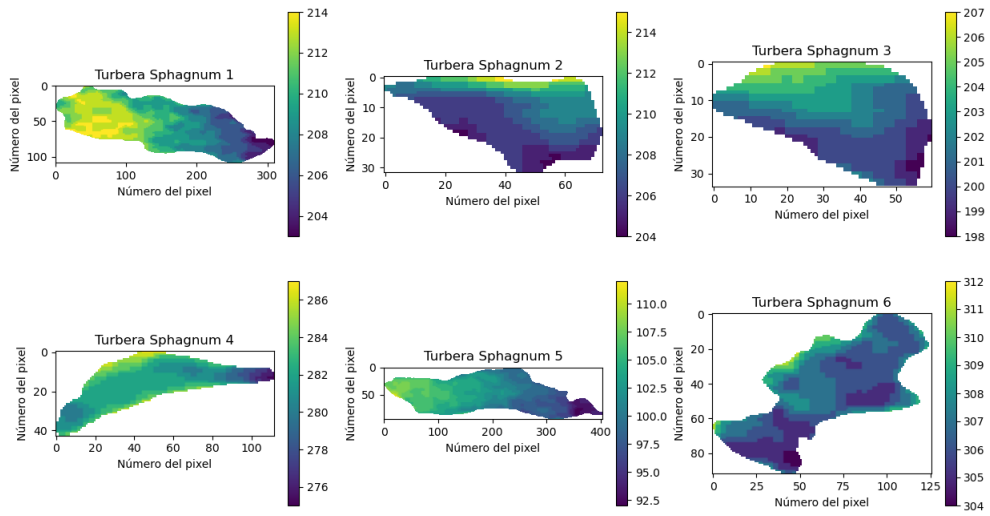


Figura A.49: Mapa de calor de Elevación para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Elevación [m] en Otras Turberas

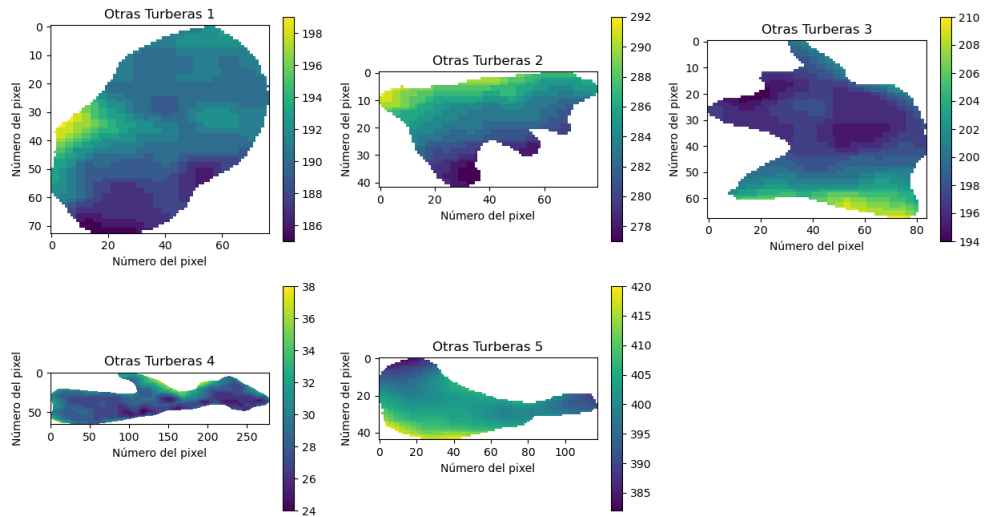


Figura A.50: Mapa de calor de Elevación para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Elevación [m] en Turberas Impactadas




Figura A.51: Mapa de calor de Elevación para polígonos de “Turberas Impactadas” (Elaboración propia).

A.7.2. Funciones densidad de probabilidad

Histogramas de Elevación [m] en Otras Turberas (individuales)




Figura A.52: Función densidad de probabilidad de Elevación en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Elevación [m] en Turberas Sphagnum (individuales)




Figura A.53: Función densidad de probabilidad de Elevación en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Elevación [m] en Turberas Impactadas (individuales)




Figura A.54: Función densidad de probabilidad de Elevación en polígonos de “Turberas Impactadas” (Elaboración propia).

A.7.3. Agrupados

Alfa agrupada por clase (método KDE)




Figura A.55: Elevación agrupada por clase (Elaboración propia).

A.7.4. Resumen




Figura A.56: Elevación: Gráfico resumen (Elaboración propia).

A.8. Pendiente

A.8.1. Mapas de Calor

Mapa de calor: Pendiente [°] en Turberas Sphagnum

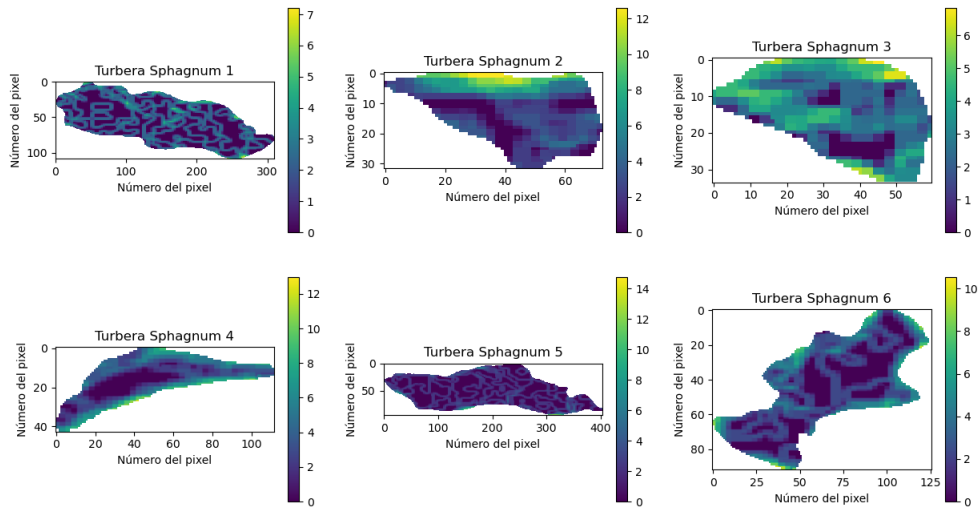


Figura A.57: Mapa de calor de Pendiente para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Pendiente [°] en Otras Turberas

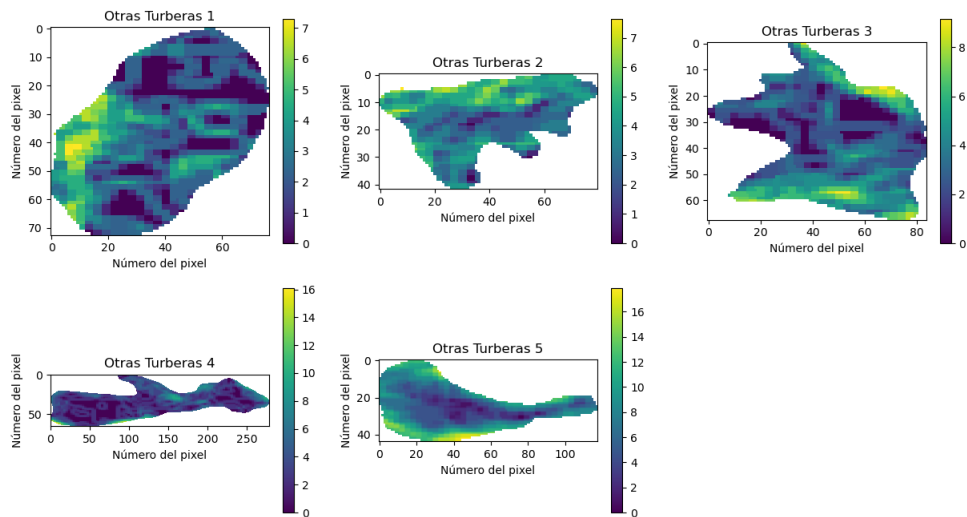


Figura A.58: Mapa de calor de Pendiente para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Pendiente [°] en Turberas Impactadas




Figura A.59: Mapa de calor de Pendiente para polígonos de “Turberas Impactadas” (Elaboración propia).

A.8.2. Funciones densidad de probabilidad

Histogramas de Pendiente [°] en Otras Turberas (individuales)

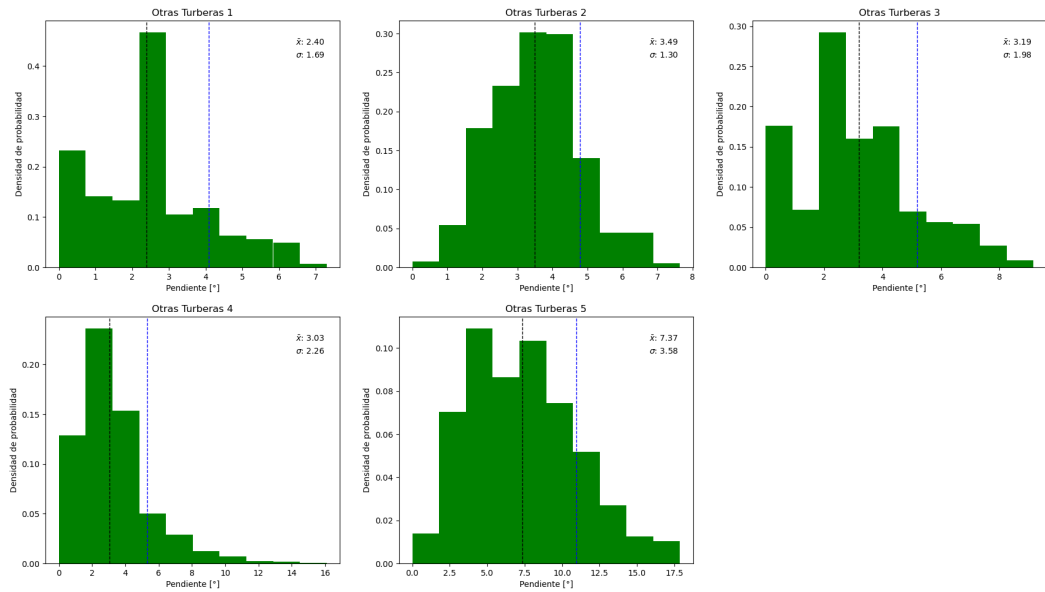


Figura A.60: Función densidad de probabilidad de Pendiente en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Pendiente [°] en Turberas Sphagnum (individuales)




Figura A.61: Función densidad de probabilidad de Pendiente en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Pendiente [°] en Turberas Impactadas (individuales)




Figura A.62: Función densidad de probabilidad de Pendiente en polígonos de “Turberas Impactadas” (Elaboración propia).

A.8.3. Agrupados

Pendiente [°] agrupada por clase (método KDE)




Figura A.63: Pendiente agrupada por clase (Elaboración propia).

A.8.4. Resumen




Figura A.64: Pendiente: Gráfico resumen (Elaboración propia).

A.9. Orientación

A.9.1. Mapas de Calor

Mapa de calor: Orientación [°] en Turberas Sphagnum

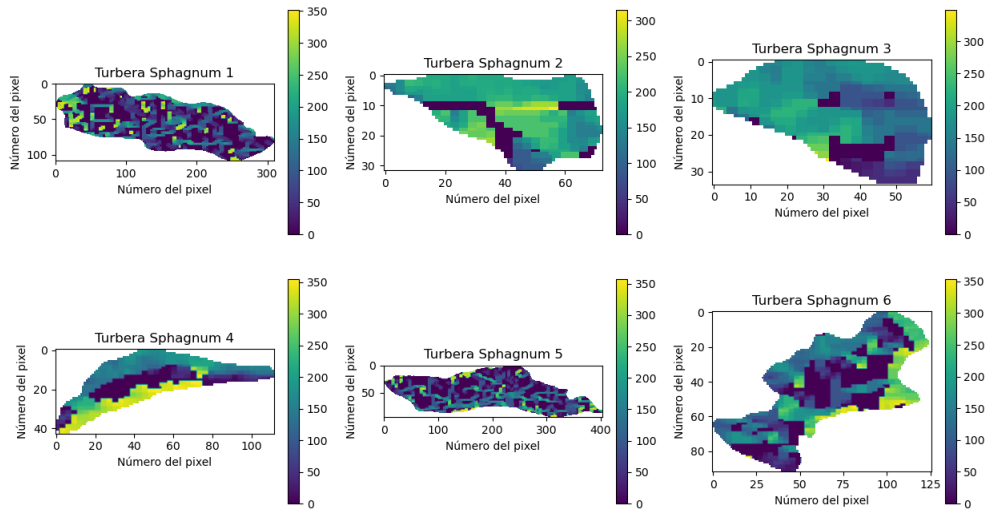


Figura A.65: Mapa de calor de Orientación para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Orientación [°] en Otras Turberas

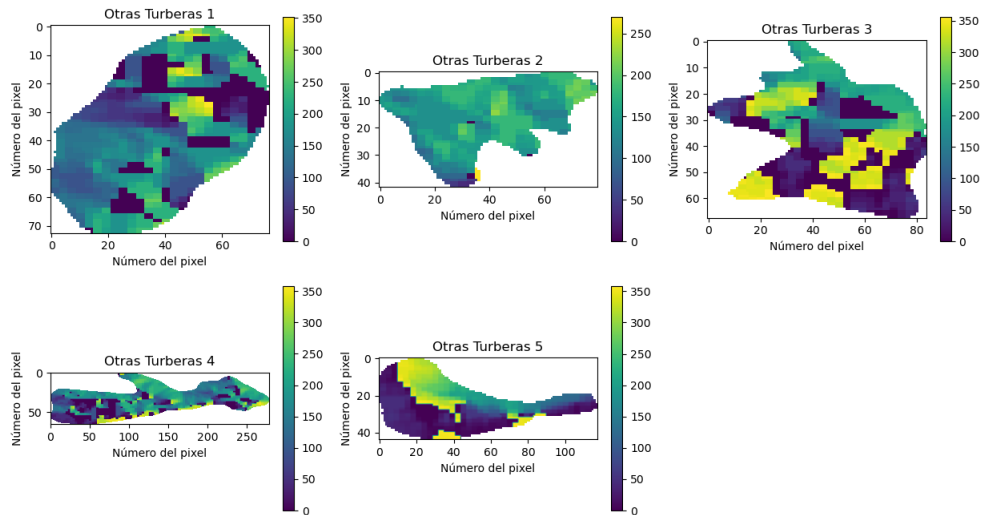


Figura A.66: Mapa de calor de Orientación para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Orientación [°] en Turberas Impactadas




Figura A.67: Mapa de calor de Orientación para polígonos de “Turberas Impactadas” (Elaboración propia).

A.9.2. Funciones densidad de probabilidad

Histogramas de Orientación [°] en Otras Turberas (individuales)




Figura A.68: Función densidad de probabilidad de Orientación en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Orientación [°] en Turberas Sphagnum (individuales)




Figura A.69: Función densidad de probabilidad de Orientación en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Orientación [°] en Turberas Impactadas (individuales)




Figura A.70: Función densidad de probabilidad de Orientación en polígonos de “Turberas Impactadas” (Elaboración propia).

A.9.3. Agrupados

Orientación [°] agrupada por clase (método KDE)




Figura A.71: Orientación agrupada por clase (Elaboración propia).

A.9.4. Resumen




Figura A.72: Orientación: Gráfico resumen (Elaboración propia).

A.10. Sombreado

A.10.1. Mapas de Calor

Mapa de calor: Sombreado en Turberas Sphagnum

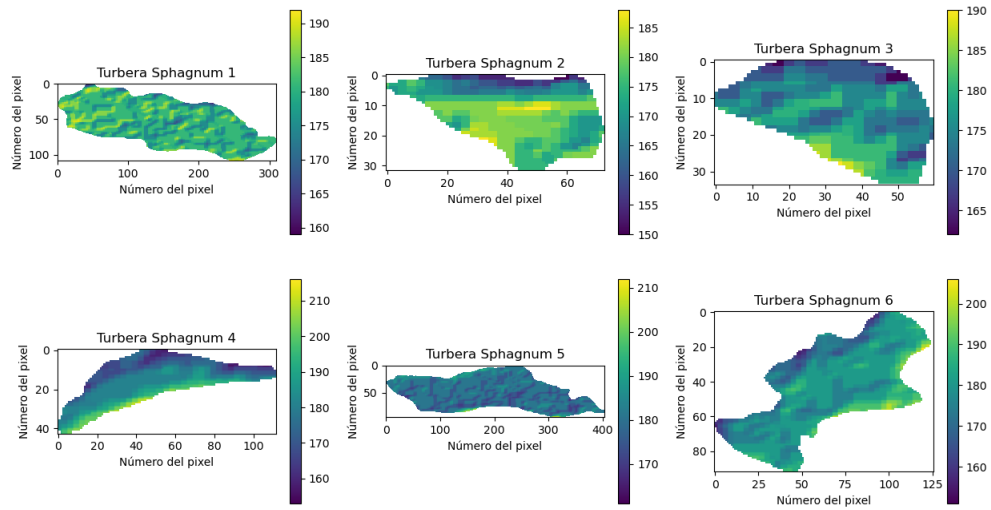


Figura A.73: Mapa de calor de Sombreado para polígonos de “Turberas Sphagnum” (Elaboración propia).

Mapa de calor: Sombreado en Otras Turberas

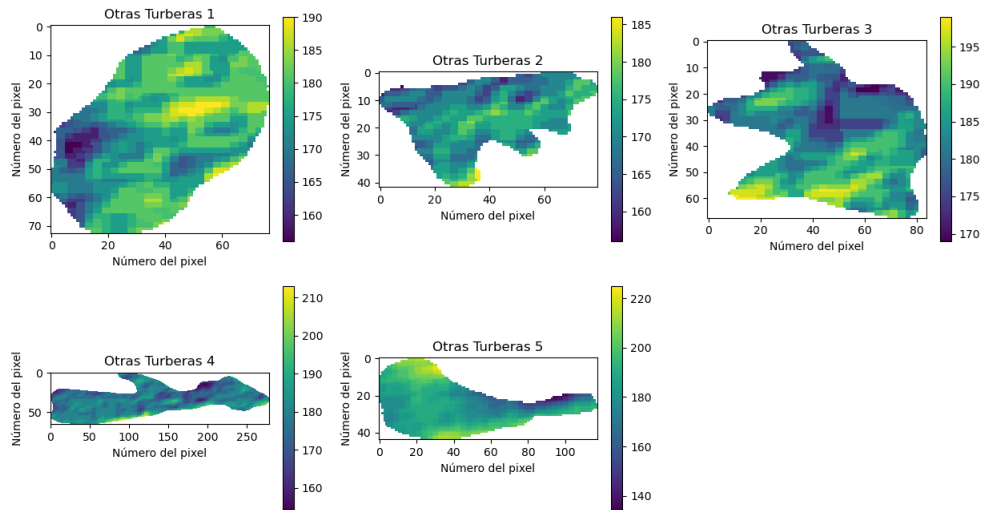


Figura A.74: Mapa de calor de Sombreado para polígonos de “Otras Turberas” (Elaboración propia).

Mapa de calor: Sombreado en Turberas Impactadas




Figura A.75: Mapa de calor de Sombreado para polígonos de “Turberas Impactadas” (Elaboración propia).

A.10.2. Funciones densidad de probabilidad

Histogramas de Sombreado en Otras Turberas (individuales)




Figura A.76: Función densidad de probabilidad de Sombreado en polígonos de “Otras Turberas” (Elaboración propia).

Histogramas de Sombreado en Turberas Sphagnum (individuales)




Figura A.77: Función densidad de probabilidad de Sombreado en polígonos de “Turberas Sphagnum” (Elaboración propia).

Histogramas de Sombreado en Turberas Impactadas (individuales)




Figura A.78: Función densidad de probabilidad de Sombreado en polígonos de “Turberas Impactadas” (Elaboración propia).

A.10.3. Agrupados

Sombreado agrupada por clase (método KDE)




Figura A.79: Sombreado agrupada por clase (Elaboración propia).

A.10.4. Resumen




Figura A.80: Sombreado: Gráfico resumen (Elaboración propia).