

2017

TELEDETECCIÓN SATELITAL Y ESPECTROMETRÍA DE CAMPO COMO HERRAMIENTAS PARA LA ESTIMACIÓN DEL CONTENIDO DE HUMEDAD DE LA ESPACIE PINUS RADIATA EN LA V REGIÓN DE VALPARAISO.

VALDIVIA GAVILÁN, JORGE ALBERTO

<http://hdl.handle.net/11673/40958>

Repositorio Digital USM, UNIVERSIDAD TECNICA FEDERICO SANTA MARIA

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
ACADEMIA DE CIENCIAS AERONÁUTICAS
SANTIAGO - CHILE

**TELEDETECCIÓN SATELITAL Y ESPECTROMETRÍA DE CAMPO COMO
HERRAMIENTAS PARA LA ESTIMACIÓN DEL CONTENIDO DE HUMEDAD
DE LA ESPECIE PINUS RADIATA EN LA V REGIÓN DE VALPARAÍSO**

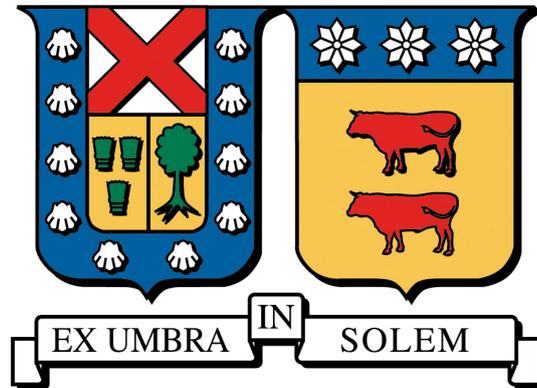
JORGE ALBERTO VALDIVIA GAVILÁN

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO EN AVIACIÓN COMERCIAL

PROFESOR GUÍA : SR. PEDRO RESZKA C.
PROFESOR CORREF. 1 : SRA. ROXANA TRUJILLO.
PROFESOR CORREF. 2 : SR. RODRIGO SUÁREZ.

OCTUBRE 2017

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
ACADEMIA DE CIENCIAS AERONÁUTICAS
SANTIAGO - CHILE



**TELEDETECCIÓN SATELITAL Y ESPECTROMETRÍA DE CAMPO COMO
HERRAMIENTAS PARA LA ESTIMACIÓN DEL CONTENIDO DE HUMEDAD
DE LA ESPECIE PINUS RADIATA EN LA V REGIÓN DE VALPARAÍSO**

JORGE ALBERTO VALDIVIA GAVILÁN

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO EN AVIACIÓN COMERCIAL

PROFESOR GUÍA : SR. PEDRO RESZKA C.
PROFESOR CORREF. 1 : SRA. ROXANA TRUJILLO.
PROFESOR CORREF. 2 : SR. RODRIGO SUÁREZ.

OCTUBRE 2017

Resumen

El presente trabajo abarca la intersección de dos áreas de la ciencia: la teledetección satelital y la espectrometría de campo, con la finalidad de estimar el FMC (*Fuel Moisture Content*), indirectamente, a partir de modelos estadísticos con índices tanto a nivel híperespectral (espectrometría) utilizando modelos de transferencia radiativa (PROSPECT) para ampliar el rango espectral, como índices espectrales a nivel satelital. El FMC es una de las variables más relevantes al momento de evaluar la gestión del riesgo de incendios forestales, explicando variables críticas como el proceso de ignición y la propagación del fuego.

La obtención de muestras de vegetación viva (*pinus radiata*) se realizó en la Reserva Lago Peñuelas de la CONAF (V Región de Valparaíso) durante el verano del 2017. Estas muestras se analizaron en el laboratorio EC²G (UTFSM, Casa Central) donde se obtuvo el FMC, el EWT (*Equivalent Water Thickness*), el DMC (*Dry Matter Content*), el espectro de reflexión comprendido entre los 650–1.100 nm, entre otras variables. Todas las pruebas se realizaron un día después del paso del satélite, con el fin de corroborar que la imagen no tuviese ruido atmosférico en la zona bajo análisis y así hacer el proceso más eficiente. Se simuló el espectro reflectivo de la vegetación comprendido entre los 400–2.500 nm utilizando PROSPECT, con el fin de contar con un rango más amplio de índices espectrales.

Las variaciones del FMC obtenidos en laboratorio de las 11 muestras estudiadas variaron entre los 122,19 % a los 157,05 % con una media de 139,25 % de humedad de los combustibles para el período de muestreo. A su vez, se empleó una metodología para determinar el FMC a partir del cociente entre el EWT y DMC a nivel de hoja (obtenidos en laboratorio), que consistió en determinar el peso fresco, seco y área de 10 agujas representativas de pino de la muestra total, donde se obtendría, de esta forma, dichas variables para una aguja de pino representativa de la muestra. El rango de valores para el FMC metodológico varió entre 123,30 % y 154,15 % con una media de 135,74 %. El FMC con respecto a la metodología empleada se explicó con una correlación de $R^2=0,76$, donde el FMC metodológico tendió a subestimar los valores del FMC medido. Se calcularon los índices para determinar, indirectamente, los valores del EWT y DMC a nivel de hoja. En el caso del EWT los mejores índices fueron el NMDI ($R^2=0,872$) y el WI ($R^2=0,869$) con RMSE de 0,001899 (g/cm^2) y 0,001921 (g/cm^2), respectivamente. En el caso del DMC se propone el WI como el mejor índice, donde el modelo se explicó con una correlación de $R^2=0,933$ y RMSE de 0,000988 (g/cm^2). A nivel satelital, tanto el EWT_{Leaf} como el DMC_{Leaf} se multiplicaron por el LAI (*Leaf Area Index*), que se obtuvo del producto MCD15A2H del sensor Modis de NASA, con el fin de obtener sus valores a nivel del dosel. Así, el EWT_{Canopy} y DMC_{Canopy} obtuvieron sus mejores resultados con el NDII ($R^2=0,837$) y el NBR ($R^2=0,8356$), respectivamente, donde los valores RMSE fueron de 0,00682 (g/cm^2) para el EWT_{Canopy} y 0,00477 (g/cm^2) para el DMC_{Canopy} .

Aplicando los modelos del EWT y DMC se obtiene la estimación del FMC a partir de información espectral. Tanto en el caso híperespectral como satelital el modelo se ajustó de mejor forma al comparar los valores con el FMC determinado por la metodología empleada. En el caso del FMC por espectrometría se obtuvo un RMSE de 14,20 % y 13,73 % para el FMC medido en el laboratorio y el FMC metodológico, respectivamente. En el caso satelital, se obtuvo un RMSE de 10,80 % y 8,50 % para el FMC medido en el laboratorio y el FMC metodológico, respectivamente. En ambos casos el modelo tendió a generar una mayor dispersión de los datos experimentales.

Abstract

The present work covers the intersection of two science areas: remote sensing and field spectrometry of vegetation with the objective of estimating the FMC (Fuel Moisture Content), indirectly, from statistical models with both hyperspectral (spectrometry) using radiative transfer models (PROSPECT) to expand the spectral range, and multispectral (satellite spectral indices). The FMC is one of the most relevant variables at the moment of evaluating the risk management of forest fires, explaining critical variables such as the time to ignition and fire behaviour.

The collection of samples of live vegetation (*pinus radiata*) was held in the Reserva Lago Peñuelas of CONAF (V Region of Valparaíso, Chile), during the summer of 2017. These samples were analyzed at the EC²G laboratory (UTFSM, Casa Central) where the FMC, EWT (Equivalent Water Thickness), DMC (Dry Matter Content), the reflective spectrum between 650–1,100 nm, among other variables, were obtained. All sampling was done a day after the passage of the satellite in order to corroborate that the image did not have atmospheric noise in the area under analysis and make the process more efficient. The reflective spectrum of vegetation was simulated between 400–2,500 nm using PROSPECT in order to have a broader range of spectral indices.

The variations of the FMC obtained in the laboratory of the 11 samples under study varied between 122.19 % to 157.05 % with an average of 139.25 % moisture content of the fuels in the sampling period. At the same time, a methodology for the determination of the FMC from the quotient between the EWT and DMC at leaf level (obtained in the laboratory) was calculated, which consisted in measuring the fresh weight, dry weight and area of 10 pine needles, representative of the total sample, with the objective to estimate the same variables for one pine needle, which would represent an average pine needle from the total sample. The range of values for the methodological FMC varied between 123.30 % and 154.15 % with an average of 135.74 %. The relation of FMC with respect to the methodology used ($FMC_{\text{Metodología}}$) was explained with a correlation of $R^2=0.76$, where the latter tended to underestimate the measured FMC values. Spectral indices were calculated to determine indirectly the values of the EWT and DMC at leaf level. In the case of the EWT, the best indices were the NMDI ($R^2=0.872$) and the WI ($R^2=0.869$) with RMSE of 0.001899 (g/cm^2) and 0.001921 (g/cm^2), respectively. In the case of the DMC, the proposed index is the WI, where the model is explained with a correlation of $R^2=0.933$ and RMSE of 0.000988 (g/cm^2). At satellite level, both EWT_{Leaf} and DMC_{Leaf} were multiplied by the Leaf Area Index (LAI), obtained from NASA's Modis product MCD15A2H, in order to obtain those values at canopy level. Thus, the estimation of EWT_{Canopy} and DMC_{Canopy} had its best results with the NDII ($R^2=0.8371$) and NBR ($R^2=0.8356$) indices, respectively. The RMSE values were 0.00682 (g/cm^2) for the EWT_{Canopy} and 0.00477 (g/cm^2) for the DMC_{Canopy} .

The FMC is equal to the quotient of EWT and DMC. Therefore, by applying the models of both, the EWT and DMC, the FMC can be estimated from hyperspectral and satellite indices. In both cases, the estimated FMC adjusted better with the methodological FMC. The FMC estimated from hyperspectral information had RMSE values of 14,20 % and 13,73 % for the measured FMC and methodological FMC, respectively. At satellite level, the FMC model obtained RMSE values of 10.80 % and 8.50 % for the measured FMC and methodological FMC, respectively. In both cases, the model tended to generate a greater dispersion of the experimental data.

Agradecimientos

En este largo camino han habido varias personas involucradas. A continuación procederé (intentaré) agradecer a cada una de ellas.

Agradezco a mis padres: gracias por brindarme tanto cariño, apoyo y la oportunidad de estudiar. No estuvieron físicamente presentes en todo este tiempo que he trabajado en el proyecto, pero de una u otra forma siempre estuvieron ahí, apoyándome y ayudándome. Este trabajo se los dedico a ustedes.

Quiero agradecer a Nicole, mi novia. Gracias por estar ahí en todos esos momentos cuando creía no había salida, cuando se presentaban problemas, cuando pensaba que no podría continuar. Gracias por tus compañías, por todas las charlas y por siempre tratar de entender lo que te explicaba del proyecto aunque se alejase en 360° de tu conocimiento. ¡Gracias por acompañarme a recolectar muestras!

A mi profesor guía, Pedro Reszka. En un comienzo, cuando me pidió leer *Fire Dynamics* de Drysdale sé que no confiaba en mí. Pero yo estaba entusiasmado y quería hacer algo distinto; creo que se lo pude demostrar. Usted fue un impulsor en esto. Gracias a usted encontré una motivación por algo que no sabía que tenía: la investigación. ¡Gracias por confiar en mí!

A Carola Contreras por su apoyo y por todas aquellas discusiones que tuvimos en varias temáticas relacionadas tanto en su proyecto como en el mío, ¡sin duda la mejor compañera de laboratorio!

Agradezco a Gonzalo Olivares, quien me ayudó en el laboratorio para hacer todo de forma más eficiente. A la Reserva Lago Peñuelas por permitirme recolectar las muestras ahí, específicamente gracias a don Aldo Valdivia Ahumada.

Quiero agradecer a la profesora Roxana Trujillo, quien pudo destapar en mí una pasión por una ciencia con su cátedra: la teledetección.

También me gustaría agradecer a mis amigos de CIREN del área de procesamiento de imágenes y modelamientos: Felipe Albornoz, Marcelo Durán, Claudio Olguín, Paula Pérez y Sergio Maldonado, quienes me acogieron en mi práctica profesional y tuve la gran oportunidad de aprender bastante en lo referente a imágenes satelitales y el procesamiento de las mismas.

Cuando uno presencia que algo está bien hecho, soy de las personas que cree que darlo a conocer y elogiarlo es un acto de honestidad intelectual: Gracias profesores Pedro Reszka y Roxana Trujillo, son grandes profesionales con grandes aspiraciones, son de esos profesores que uno jamás olvidará.

Agradezco a mis amigos, a aquellos que muchas veces tuve que correr esas juntas por el simple hecho de estar trabajando en el presente proyecto. ¡Disculpen!

Quiero agradecer al Veganismo, que me ha llevado a ser una persona más crítica y escéptica en todo sentido. Y por qué no... Gracias Jack, mi erizo de tierra, por todos estos años de compañía y aventuras. Falleciste justo una semana antes de que terminase de escribir la memoria. Ahora eres polvo de estrellas, de donde vinimos, de lo que todos estamos hechos. Descansa en paz.

... “Look again at that dot. That’s here. That’s home. That’s us. On it everyone you love, everyone you know, everyone you ever heard of, every human being who ever was, lived out their lives. The aggregate of our joy and suffering, thousands of confident religions, ideologies, and economic doctrines, every hunter and forager, every hero and coward, every creator and destroyer of civilization, every king and peasant, every young couple in love, every mother and father, hopeful child, inventor and explorer, every teacher of morals, every corrupt politician, every “superstar”, every “supreme leader”, every saint and sinner in the history of our species lived there-on a mote of dust suspended in a sunbeam.”

Carl Sagan,
Pale Blue Dot.

ÍNDICE GENERAL

Resumen	v
Abstract	vii
Agradecimientos	ix
Índice General	xv
Índice de Figuras	xix
Índice de Tablas	xxii
Nomenclatura	xxiii
Símbolos	xxv
Introducción	xxvii
1. Antecedentes Generales	29
1.1. Justificación del tema	29
1.2. Objetivos	31
1.2.1. Objetivo general	31
1.2.2. Objetivos específicos	31
1.3. Alcance de la investigación	32
2. Estado del Arte	35
2.1. Antecedentes y situación actual	35
2.1.1. Chile	36
2.1.1.1. Comisión Nacional Forestal – CONAF	36
2.1.1.1.1. Incendios forestales en Chile	36
2.1.1.1.2. Región de Valparaíso	40
2.1.1.2. Teledetección Satelital en Chile.	41
2.1.1.2.1. Entidades especializadas	47
2.1.2. Resto del mundo.	49
2.1.2.1. EE.UU.	49
2.1.2.2. Canadá.	50
2.1.2.3. Europa.	51
2.2. Teledetección Satelital	53
2.2.1. Breve introducción a la Teledetección	53
2.2.1.1. El espectro electromagnético.	53
2.2.1.2. Sensores y satélites de teledetección.	55
2.2.1.2.1. Tipos de satélites y sensores	60
2.2.2. Calibración de las imágenes satelitales	62
2.2.2.1. Corrección geométrica	63
2.2.2.2. Corrección radiométrica	63
2.2.2.2.1. Corrección atmosférica	65
2.2.3. Espectrometría	68
2.2.3.1. Regiones del espectro	70
2.2.3.2. Trabajo de campo espectral	72
2.2.3.3. Modelos de transferencia radiativa	72

2.2.3.3.1.	Bases de datos	76
2.2.4.	Índices espectrales	77
2.2.4.1.	Metodología para crear índices espectrales	89
2.3.	Biomasa como combustible de Incendios Forestales	90
2.3.1.	Leaf Area Index	93
2.3.1.1.	LAI a partir de información satelital	95
2.3.2.	Pigmentos de la vegetación	96
2.3.3.	Equivalent Water Thickness	97
2.3.4.	Dry Matter Content	100
2.3.4.1.	Leaf Mass per Area	102
2.3.5.	Fuel Moisture Content	103
2.3.6.	Desafíos para la estimación del LFMC desde información satelital	105
2.3.7.	Principales problemas en la estimación del L-FMC	108
2.3.7.1.	Errores de estimación en el L-FMC	108
2.3.8.	Trabajo de campo	109
3.	Métodos y Materiales	111
3.1.	Área de muestreo	111
3.2.	Especie de muestreo	112
3.2.1.	Descripción general de la especie	112
3.3.	Instrumentos Experimentales	113
3.3.1.	Espectrometría de campo	113
3.3.2.	Información satelital	115
3.3.3.	Otros	115
3.3.3.1.	Horno para el secado de muestras	115
3.3.3.2.	Balanza	115
3.3.3.3.	GPS	115
3.3.3.4.	Tijerón	116
3.3.3.5.	Computador	116
3.4.	Metodología	117
3.4.1.	Trabajo de campo experimental	117
3.4.2.	Análisis espectral	119
3.4.2.1.	Simulación del espectro de reflexión	120
3.4.2.2.	Procedimiento experimental para el análisis espectral	123
3.4.3.	Información Satelital	125
4.	Resultados Experimentales	127
4.1.	Resultados de laboratorio y trabajo de campo	127
4.1.1.	Trabajo de campo	127
4.1.2.	Obtención del FMC	129
4.1.3.	Espectros medidos	135
4.1.3.1.	Índices obtenidos a partir del espectro medido	140
4.2.	Información satelital	141
4.2.1.	Calibración	141
4.2.2.	Imagen por campaña	141
4.2.3.	Cálculo del EWT y DMC a nivel del dosel	143
4.2.4.	Índices espectrales satelitales	144

5. Modelamiento en PROSPECT	147
5.1. Parámetros de entrada de PROSPECT	147
5.1.1. Cantidad de clorofila a+b (C_{a+b})	147
5.1.2. Cantidad de carotenoides (C_{car})	149
5.1.3. Equivalent water thickness (EWT)	150
5.1.4. Pigmentos café – C_b	151
5.1.5. Leaf mass per area – LMA	152
5.1.6. Parámetro de estructura interna – N	152
5.2. Resultados de los parámetros para PROSPECT	153
5.3. Resultados de la simulación	156
5.3.1. Comparación del espectro medido vs espectro simulado	159
5.3.2. Índices del espectro simulado y del espectro medido	162
5.4. Comparación entre índices espectrales y satelitales	165
6. Estimación del contenido de humedad (FMC)	167
6.1. FMC por espectrometría	167
6.1.1. EWT por espectrometría	167
6.1.2. DMC por espectrometría	169
6.1.3. FMC a partir de espectrometría	172
6.2. FMC por información satelital	175
6.2.1. EWT_{Canopy} por información satelital	175
6.2.2. DMC_{Canopy} por información satelital	177
6.2.3. FMC a partir de información satelital	179
6.3. Contraste entre modelos obtenidos	182
Discusión	187
Trabajo a futuro	189
Conclusión	191
Bibliografía	195
Anexo	219
A. Áreas Homogéneas definidas por la CONAF	221
B. Características de los satélites chilenos	222
C. Calibración imágenes Landsat 8	228
D. Ejemplo de simulación con PROSPECT	229
E. Resumen de mapas de modelos/tipos de combustible	231
F. Características generales de las agujas y conos de pino	232
G. Diferencias en el parámetro de estructura interna	232
H. Metodología para estimar el área de una aguja de pino con programa ImageJ	233
I. Imágenes satelitales correspondientes a la experiencia 2 y 3	234
J. Variación entre índices espectrales a nivel satelital y a nivel híperespectral	236

ÍNDICE DE FIGURAS

2. Estado del Arte	
2.1. Situación actual de Chile y el resto del mundo	35
2.2. Mapa conceptual de los términos a tratar.	36
2.3. Superficie afectada por incendios forestales entre los años 1990 y 2015.	38
2.4. Esquema de los sistemas de detección.	39
2.5. Ciclos de misión y producción del G.O.E.	42
2.6. Agricultura de precisión con imágenes satelitales.	43
2.7. Gestión de emergencias volcánicas con imágenes satelitales	43
2.8. Incendios en la Región del Bío-Bío, Chile.	44
2.9. Imagen del “Gran incendio de Valparaíso” captada por el SSOT.	45
2.10. Bases cartográficas por medio de información satelital	45
2.11. Control de crecimiento urbano con imágenes satelitales.	46
2.12. Proceso del <i>International Charter & Major Disasters</i>	48
2.13. Índice NFDRS estadounidense	50
2.14. Índice CFFDRS canadiense	51
2.15. Índice Europeo	52
2.17. El espectro electromagnético	54
2.18. Resolución espacial	56
2.19. Resolución espectral	57
2.20. Resolución radiométrica	58
2.21. Órbitas principales de los satélites.	60
2.22. Ejes de acción de un satélite.	62
2.23. Proceso de la calibración radiométrica.	64
2.24. Efectos atmosféricos sobre el cálculo de la reflectividad.	65
2.25. Descomposición del flujo solar incidente.	68
2.26. Reflectancia de vegetación viva de la especie <i>Pinus Radiata</i>	70
2.27. Tipos de reflectancia.	73
2.28. Estructura interna de la vegetación.	73
2.29. Modelos de transferencia radiativa a nivel de hoja.	75
2.30. Desafíos para la estimación del L-FMC por medio de información satelital.	105
3. Métodos y Materiales	
3.1. Esquema de los contenidos a tratar.	111
3.4. Horno y balanza utilizados en la experimentación.	116
3.5. GPS y Tijeron utilizados en la experimentación.	116
3.6. Proceso de recolección de muestras	118
3.7. Variaciones en los parámetros de entrada de PROSPECT.	124
4. Resultados Experimentales	
4.1. Esquema de los contenidos del capítulo Resultados Experimentales.	127
4.2. Mapa del bosque en la Reserva Lago Peñuelas donde se recolectaron las muestras.	128
4.3. Mapa de los puntos de recolección en el bosque de la Reserva Lago Peñuelas.	129
4.4. Gráfico de las áreas de hojas y sus desviaciones estándar por muestra	130
4.5. Imagen de las muestras previo al secado en el horno.	131
4.6. FMC medido en laboratorio versus el cociente entre EWT_{Leaf} y DMC_{Leaf}	133
4.7. Diagrama de cajas para una comparación visual entre el FMC_{Medido} y el $FMC_{Metodología}$	134

4.8. Gráficos del espectro medido para la experiencia 1.	135
4.9. Gráficos del espectro medido para la experiencia 2.	136
4.10. Gráficos del espectro medido para la experiencia 3.	137
4.11. Gráficos resumen de los espectro medidos para todas las experiencias.	139
4.12. Ejemplo de la estadística de la imagen satelital correspondiente a la experiencia 1.	142
4.13. Imagen satelital correspondiente a la experiencia 1.	142
4.14. NDVI para la experiencia 1.	143
4.15. Rango de valores de los índices espectrales obtenidos por información satelital.	145
5. Modelamiento en PROSPECT	
5.1. Relación lineal entre la cantidad de clorofila a+b (C_{a+b}) y el Índice de Gitelson.	148
5.2. Relación lineal entre la cantidad de carotenoides (C_{car}) y el Índice de Gitelson.	149
5.3. Relación lineal entre el EWT y el Water Index.	151
5.4. Gráficas comparativas de las diferencias entre el EWT medido en laboratorio y aquel obtenido por el modelo de regresión.	154
5.5. Gráficos del espectro simulado para la experiencia 1.	156
5.6. Gráficos del espectro simulado para la experiencia 2.	157
5.7. Gráficos del espectro simulado para la experiencia 3.	158
5.8. Gráficos del espectro simulado y medido para la experiencia 1.	159
5.9. Gráficos del espectro simulado y medido para la experiencia 2.	160
5.10. Gráficos del espectro simulado y medido para la experiencia 3.	161
5.11. Gráficos de caja de las diferencias entre los índices para espectro medido y simulado.	163
5.12. Diferencias entre índices medidos y simulados.	164
5.13. Comparación gráfica de los índices medidos versus los simulados.	164
5.14. Diferencias entre índices a nivel espectral y satelital.	166
6. Estimación del contenido de humedad (FMC)	
6.1. Gráficos de correlaciones para el EWT_{Leaf} a partir de índices espectrales.	169
6.2. Gráficos de correlaciones para el DMC_{Leaf} a partir de índices espectrales.	171
6.3. Diagrama de caja de la variación del FMC del modelo elaborado por espectrometría en comparación al FMC_{Medido} y $FMC_{Metodología}$	173
6.4. Variación del modelo para estimar el FMC por espectrometría con respecto a los datos obtenidos experimentalmente.	174
6.5. Gráficos de regresión para el EWT_{Canopy} versus el NDII y SIWSI a nivel satelital	176
6.6. Gráficos de regresión para el DMC_{Canopy} versus el NBR y SIWSI a nivel satelital	177
6.7. Diagrama de caja de la variación del FMC del modelo elaborado por información satelital en comparación al FMC_{Medido} y $FMC_{Metodología}$	180
6.8. Variación del modelo para estimar el FMC por información satelital con respecto a los datos obtenidos experimentalmente.	181
6.9. Comparación del rango de valores obtenidos para los modelos y los valores experimentales del FMC.	182
6.10. Comparación de las variaciones de los modelos con respecto a los valores experimentales del FMC.	183
6.11. Diagramas de caja de la variación del FMC aplicando el modelo del FMC_s a los datos hiperespectrales.	184
6.12. Gráfica de subestimación de los valores experimentales por parte de los modelos del FMC al aplicar el modelo del FMC_s a nivel hiperespectral.	185

Anexo

D.1. Fotografías de muestras de especies de LOPEX93	229
D.2. Ejemplo de firmas espectrales con PROSPECT	230
G.1. Diferencias en los parámetros de estructura interna (N) para PROSPECT.	232
I.1. Imagen satelital correspondiente a la experiencia 2.	234
I.2. Imagen satelital correspondiente a la experiencia 3.	235
J.1. Variación entre índices a nivel satelital y a nivel híperspectral.	236

ÍNDICE DE TABLAS

2. Estado del Arte	
2.1. Resumen de las características descritas en las tablas B.4, B.5, B.6 y B.7.	61
2.2. Parámetros de entrada de los modelos PROSPECT y LIBERTY.	75
2.3. Rangos de bandas del espectro electromagnético	77
2.4. Índices espectrales con sus correspondientes ventajas y contras	78
2.5. Recopilación bibliográfica del secado de muestras con la metodología del <i>Ovendry Weight</i>	110
3. Métodos y Materiales	
3.1. Características del espectrómetro y de la fibra óptica.	113
4. Resultados Experimentales	
4.1. Fechas de visitas de recolección de muestras más trabajo de laboratorio.	128
4.2. Resultados del FMC con la técnica del <i>Ovendry Weight</i>	130
4.3. Resultados para el análisis de 1 aguja de pino.	132
4.4. FMC medido vs FMC de la metodología empleada.	132
4.5. Algunos índices espectrales que se pueden calcular a partir de la información obtenida por el espectrómetro	140
4.6. Imágenes Landsat 8 utilizadas por cada experiencia.	141
4.7. Valores de LAI, EWT_{CANOPY} y DMC_{CANOPY} de cada experiencia.	144
4.8. Valores mínimos, máximos, medios y desviación estándar de los índices espectrales obtenidos a través de información satelital.	145
5. Modelamiento en PROSPECT	
5.1. Parámetros de entrada de PROSPECT.	147
5.2. Rango de valores de clorofila a+b de las muestras de LOPEX93	149
5.3. Rango de valores de los carotenoides de las muestras de LOPEX93	150
5.4. Rango de valores del EWT de las muestras de LOPEX93	151
5.5. Resultados de los modelos estadísticos para determinar la clorofila, EWT y carotenoides.	153
5.6. Resultados experimentales del LMA, EWT_{Leaf} y N.	155
5.7. Índices espectrales medidos (experimentales) versus los índices espectrales simulados.	162
5.8. Valores medios de los errores experimentales por índice espectral analizado.	163
5.9. Relaciones entre información satelital y espectral para mismos índices	166
6. Estimación del contenido de humedad (FMC)	
6.1. Correlaciones para el EWT_{Leaf} a partir de índices espectrales del espectro simulado.	168
6.2. Correlaciones para el DMC_{Leaf} a partir de índices espectrales.	170
6.3. Síntesis de casos para la comparación de resultados del FMC_e	173
6.4. Correlaciones para el EWT_{Canopy} a partir de índices espectrales a nivel satelital.	175
6.5. Correlaciones para el DMC_{Canopy} a partir de índices espectrales a nivel satelital.	177
6.6. Síntesis de casos para la comparación de resultados del FMC_s	180
6.7. Escenarios a estudiar para los RMSE de los modelos del FMC_s aplicado a información híperespectral.	185

Anexo

A.1. Códigos de las áreas homogéneas de la CONAF.	221
B.1. Características del satélite FASat – Alfa.	222
B.2. Características del satélite FASat – Bravo.	222
B.3. Características del satélite FASat – Charlie (SSOT)	223
B.4. Principales características de sensores	224
D.1. Ejemplo para obtener la curva espectral de diversas especies mediante PROSPECT	229
E.1. Resumen bibliográfico de la clasificación digital de mapas de combustibles.	231
F.1. Características generales de agujas y conos de pino.	232

Nomenclatura

NASA	<i>National Aeronautics and Space Administration</i>
USGS	<i>United States Geological Survey</i>
UNISDR	<i>United Nations Office for Disaster Risk Reduction</i>
FS	<i>Forest Service</i>
CONAF	<i>Comisión Nacional Forestal</i>
ONEMI	<i>Oficina Nacional de Emergencias</i>
WUI	<i>Wildland Urban Interface</i>
NFDRS	<i>National Fire Danger Rating System</i>
CFFDRS	<i>Canadian Forest Fire Danger Rating System</i>
EFFIS	<i>European Forest Fire Information System</i>
USGS	<i>United States Geological Survey</i>
FS	<i>Forest Service</i>
SSOT	<i>Sistema Satelital de Observación Terrestre</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
SPOT	<i>Satellite Pour l'Observation de la Terre</i>
EOS	<i>Earth Observing System</i>
EO	<i>Earth Observation</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
AVHRR	<i>Advanced Very High Resolution Radiometer</i>
LIDAR	<i>Light Detection and Ranging</i>
SAR	<i>Synthetic Aperture Radar</i>
TM	<i>Thematic Mapper</i>
ETM	<i>Enhanced Thematic Mapper</i>
OLI	<i>Operational Land Imager</i>
MSS	<i>Multispectral Sensor</i>
TOA	<i>Top of Atmosphere</i>
LEO	<i>Low Earth Orbit</i>
MEO	<i>Mid-altitude Earth Orbit</i>
GEO	<i>Geosynchronous and Geostationary Earth Orbits</i>
VIS	<i>Visible Spectrum</i>
NIR	<i>Near Infrared</i>
SWIR	<i>Shortwave Infrared</i>
MIR	<i>Middle Infrared</i>
TIR	<i>Thermal Infrared</i>
IFOV	<i>Instantaneous Field Of View</i>
DN	<i>Digital Number</i>
BRDF	<i>Bidirectional Reflectance Distribution Function</i>
UTM	<i>Universal Transverse Mercator</i>

SIG	<i>Sistema de Información Geográfica</i>
WGS	<i>World Geodetic System</i>
NDWI	<i>Normalized Difference Water Index</i>
WI	<i>Water Index</i>
VSI	<i>Vegetation Stress Index</i>
IG	<i>Índice de Gitelson</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDII	<i>Normalized Difference Infrared Index</i>
MSI	<i>Moisture Stress Index</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
NSAVI	<i>Modified Soil Adjusted Vegetation Index</i>
TSAVI	<i>Transformed Soil Adjusted Vegetation Index</i>
GNDVI	<i>Green Normalized Difference Infrared Index</i>
ARVI	<i>Atmospherically Resistant Vegetation Index</i>
NMDI	<i>Normalized Multi-band Drought Index</i>
NDMI	<i>Normalized Dry Matter Index</i>
VARI	<i>Visible Atmospherically Resistant Index</i>
RSR	<i>Reduced Simple Ratio</i>
VI _{green}	<i>Vegetation Index (green)</i>
EVI	<i>Enhanced Vegetation Index</i>
GVMi	<i>Global Vegetation Moisture Index</i>
FMC	<i>Fuel Moisture Content</i>
L-FMC	<i>Live Fuel Moisture Content</i>
D-FMC	<i>Dead Fuel Moisture Content</i>
FMC _{Medido}	<i>FMC medido en laboratorio para toda la muestra</i>
FMC _{Metodológico}	<i>FMC obtenido a partir del cociente del EWT y DMC a nivel de hoja</i>
FMC _e	<i>Modelo del FMC a partir de información híperespectral (a nivel de hoja)</i>
FMC _s	<i>Modelo del FMC a partir de información satelital (a nivel del dosel)</i>
ODW	<i>Ovendry Weight</i>
EWT	<i>Equivalent Water Thickness</i>
DMC	<i>Dry Matter Content</i>
EWT _{Canopy}	<i>Equivalent Water Thickness at Canopy level</i>
DMC _{Canopy}	<i>Dry Matter Content at Canopy level</i>
CWC	<i>Canopy Water Content</i>
LWC	<i>Leaf Water Content</i>
LMA	<i>Leaf Mass per Area</i>
SLA	<i>Specific Leaf Area</i>
LAI	<i>Leaf Area Index</i>
FCCs	<i>Fuel Characteristics Classification System</i>
RS	<i>Remote Sensing</i>

RSAC	<i>Remote Sensing Applications Center</i>
WFAS	<i>Wildland Fire Assessment System</i>
RTM	<i>Radiative Transfer Model</i>
PROSPECT	<i>Leaf Optical Properties Spectra</i>
LIBERTY	<i>Leaf Incorporating Biochemistry Exhibiting Reflectance and Transmittance Yields</i>
SAIL	<i>Scattering by Arbitrarily Inclined Leaves</i>
SAILH	<i>Scattering by Arbitrarily Inclined Leaves + Hotspot</i>
LOPEX93	<i>Leaf Optical Properties Experiment</i>
RMSE	<i>Root Mean Square Error</i>
FARSITE	<i>Fire Area Simulator-model</i>

Símbolos

A	<i>Área Superficial (cm^2)</i>
ρ	<i>Reflectancia del material</i>
α	<i>Absorbitancia del material</i>
τ	<i>Transmitancia del material</i>
ρ_λ	<i>Reflectancia en la longitud de onda λ</i>
W_f	<i>Fresh Weight</i>
W_d	<i>Dry Weight</i>
$L_{sen,k}$	<i>Radiancia espectral en la banda k</i>
$L_{suelo,k}$	<i>Contribución de la radiación que emerge de la superficie terrestre</i>
$L_{a,k}$	<i>Radiancia atmosférica debido a la dispersión</i>
$\tau_{k,0}$	<i>Transmisividad de la atmósfera en la dirección ascendente</i>
$E_{suelo,k}$	<i>Irradiancia que llega a la superficie terrestre</i>
$E_{0,k}$	<i>Irradiancia al techo de la atmósfera</i>
$E_{d,k}$	<i>Irradiancia difusa</i>
θ_i	<i>Ángulo cenital del flujo incidente</i>
$\tau_{k,i}$	<i>Transmisividad atmosférica que afecta a la irradiancia</i>
ρ_k^*	<i>Reflectancia al techo de la atmósfera</i>
D	<i>Factor de corrección de la distancia tierra-sol</i>
ρ_k	<i>Reflectancia real</i>
$a_{0,k}$ $a_{1,k}$	<i>Coefficientes de calibración para la banda k</i>
ND_{MIN}	<i>Valor mínimo del número digital</i>
N	<i>Parámetro de estructura interna de la vegetación</i>
C_{a+b}	<i>Contenido de clorofila $a+b$</i>
C_{car}	<i>Contenido de carotenoides</i>
C_b	<i>Pigmentos café</i>

Introducción

Chile se ha visto gravemente afectado en los últimos 20 años de su historia por catástrofes naturales. Es más, el Vicepresidente del Senado señaló que durante dicho lapso de tiempo, el país ha concentrado la mayor cantidad de emergencias a nivel regional ([Senado de la República de Chile, 2015](#)). Entre estas catástrofes se encuentran terremotos, maremotos, erupciones volcánicas, inundaciones, incendios forestales, entre otras, que se traducen, según el estudio realizado por la Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres (UNISDR por sus siglas en inglés), en costos que ascienden al, aproximadamente, 1,1 % del PIB del país, donde se puede destacar que al año 2011 Chile es el país que más dinero destina a estos eventos a nivel mundial ([UNISDR, 2015](#)).

El ente encargado de coordinar el sistema nacional de protección civil para estos efectos es la Oficina Nacional de Emergencias (ONEMI), organismo que además busca convertir la reducción del riesgo de desastre (RRD) en una prioridad nacional ([ONEMI, 2016](#)).

En Abril de 2014, ocurrió el denominado “Gran Incendio de Valparaíso”, el cual es considerado como uno de los mayores incendios urbanos en la historia de Chile ([FOXNEWS, 2014](#)). Dicho evento acabó con la vida de 15 personas, destruyó más de 2.900 viviendas, dejó a 12.500 personas damnificadas y un área total quemada de más de 1.000 hectáreas ([Reszka y Fuentes, 2014](#)). Más cercano a la fecha se encuentran los incendios forestales ocurridos entre enero-febrero de 2017 en las zonas centro y sur de Chile, donde hubo un total de 13 víctimas fatales por el combate del fuego, accidentes o por problemas de salud, todos relacionados directamente al desastre ([24-Horas, 2017a,b](#); [Cooperativa, 2017](#); [Emol, 2017](#)). La Comisión Nacional Forestal (CONAF) determinó que el área total afectada para los incendios ocurridos entre enero y febrero de 2017 fue de 518.174,3 hectáreas ([CONAF, 2017](#)). Los incendios se generaron entre la IV y IX Región del país, cuya mayor concentración ocurrió en la VII Región del Maule (52,2 % del total del área quemada; [Ministerio de Agricultura, 2017](#)).

Anualmente, en Chile se queman, en promedio, 46 mil hectáreas al año según estadísticas de la CONAF entre los años 1990 y 2015 ([CONAF, 2016b](#)). A su vez, se estima un monto promedio anual de pérdida económica aproximado de US\$ 50 millones ([UNESCO, 2012](#), p. 51). Cabe destacar que se espera que la situación empeore con el paso del tiempo, dado que aún no hay una institucionalidad fuerte que regule el crecimiento inorgánico que experimentan las urbes ([Castillo *et al.*, 2009](#)). A lo anterior se suma el fenómeno del cambio climático, que se manifiesta en el incremento de la temperatura promedio de la tierra, la cual podría ir de 1 – 3°C durante el próximo siglo, la prolongación de las estaciones de verano, cambios en el patrón de precipitaciones, entre otras ([National Climate Assessment, 2016](#); [Siameoni *et al.*, 2012](#)). En base a lo anterior es que existe la necesidad de elaborar herramientas o sistemas que permitan cuantificar el riesgo asociado a la ignición y propagación del fuego ([Massada *et al.*, 2009](#)).

Las zonas denominadas *Wildland–Urban Interface* (WUI) han sido durante décadas arrasadas por intensos incendios forestales. Lo anterior se debe, básicamente, porque a estos lugares se les asocia una mayor probabilidad de ignición debido a que coexiste la infraestructura humana con la vegetación ([Radeloff *et al.*, 2001](#)). De hecho, un estudio realizado en los bosques mediterráneos de Galicia, España, indica que la probabilidad de ignición en la zona WUI es prácticamente el doble en relación a una que no lo es ([Chas-Amil *et al.*, 2013](#)).

Los incendios forestales son un tema bastante complejo de controlar, pero no tan complejo de prevenir. Por medio de imágenes satelitales se pueden obtener diversos parámetros o *inputs* para establecer una tendencia a la ignición ([Burgan *et al.*, 1998](#); [Chuvienco, 2010](#)).

La razón primordial de la relación del presente proyecto con el estudio de los incendios forestales

corresponde a la aplicabilidad que se puede obtener al enlazar ciencias relacionadas con la teledetección satelital y la espectrometría de campo, y he ahí la razón de su estrecha relación para el presente estudio. En éste trabajo se busca relacionar la información satelital con la espectral a partir de índices espectrales que se enfocarán, entre otras cosas, en determinar una aproximación a lo que sería la humedad del combustible forestal, en donde existe una estrecha relación con los incendios forestales, como se verá en el [Capítulo 2](#).

Parece interesante y se espera que la teledetección satelital pueda relacionarse con bastante precisión a la información espectral (obtenida del análisis con el espectrómetro y el análisis en el laboratorio), con el fin de establecer un modelo estadístico que a futuro pueda relacionar información satelital con variables asociadas al proceso de ignición y propagación del fuego, en otras palabras: la calorimetría.

1 | Antecedentes Generales

1.1. Justificación del tema

La civilización se encuentra en el siglo XXI y, desde el siglo pasado, el ser humano se ha ido aventurando en la actividad aeroespacial, la cual, en torno al tema en cuestión, se destaca la cantidad de satélites que se han lanzado al espacio, entre ellos se encuentran los satélites de observación terrestre, meteorológicos, de navegación, de estudios científicos, de telecomunicaciones, etc. Por lo que ya es posible utilizar diversos sensores para poder detectar o estimar, por ejemplo, la humedad de sectores, la temperatura, la dirección de los vientos, entre otros. Tal es el ejemplo de sensores dentro de satélites NOAA, Aqua & Terra, WorldView, Quickbird, Landsat, entre otros; los cuales orbitan a distintas alturas con distintas misiones, pero que convergen en algo: la investigación.

En el mundo, los incendios forestales constituyen la causa más importante de destrucción de bosques, que lleva, a su vez, severos impactos ambientales y sociales que afectan a sectores urbanos y habitacionales en localidades urbano-forestal (Omi, 2005; Radeloff *et al.*, 2001; Theobald y Romme, 2007). Según la CONAF, anualmente se queman, en Chile, alrededor de 46 mil hectáreas al año (CONAF, 2016b). La superficie de la ciudad de Santiago de Chile es de aproximadamente 728 km² (INE, 2005). Así, se podría establecer la siguiente analogía. Teniendo en cuenta la cantidad de hectáreas que se queman en el país, por una simple regla de tres se podría establecer que es una equivalencia a que se quemara el 63 % de la ciudad de Santiago.

La principal causa de origen de estos eventos se radica en el ser humano y sus actividades. En efecto, la CONAF realizó un estudio estadístico entre los años 1987 y 2014 para determinar las causas de los incendios forestales, donde se determinó que, aproximadamente, el 84 % de los incendios forestales fueron provocados por el humano, el 16 % por causas desconocidas y el 0,2 % por causas naturales (CONAF, 2004). Y no es algo lejano a la realidad mundial, por ejemplo, en España el Ministerio de Agricultura, Alimentación y Medio Ambiente, realizó un estudio el año 2012 donde se estableció que sobre el 70 % de las causalidades de los incendios eran producidas por el hombre (MAGRAMA, 2012).

Ahora, si bien no es posible atenerse o prevenir los actos del ser humano en materia de incendios forestales o causas naturales, si se puede establecer, por medio de imágenes satelitales un monitoreo o estudio de información sobre el estado de la vegetación, tanto hídrico como de vigor, las temperaturas de los sectores, los vientos predominantes y la dirección de los mismos, las pendientes, entre otros, con el fin de establecer zonas con alta probabilidad de ignición¹ (Chuvieco, 2010; Chuvieco *et al.*, 2004a).

El presente trabajo busca estudiar y analizar la relación existente entre información satelital y la espectrometría de campo de la especie *Pinus Radiata*, comparando diversos índices espectrales que se recopilarán de la literatura. La finalidad es encontrar una relación estadística al utilizar la información satelital para estimar diversas propiedades intrínsecas a la vegetación, tales como la humedad del combustible de la especie bajo análisis, entre otros, que se validarán con información hiperespectral (espectrometría) y trabajo de laboratorio. De esta forma, el propósito de lo anterior es con miras a un proyecto a futuro sobre la aplicabilidad que podría tener el presente estudio para generar un modelo estadístico que pueda obtener relaciones entre información satelital y las principales variables asociadas a un incendio, en función de índices espectrales.

¹ Este tema se tratará con mayor profundidad en el [Capítulo 2](#).

Para estos efectos, se escogió la localidad de Valparaíso puesto que a ésta le corresponde una participación de un 15 % de los incendios forestales y un 15,2 % de la superficie afectada a nivel nacional (hasta el año 2011; CONAF, 2011). Es más, Valparaíso es la ciudad más afectada por incendios forestales en la zona WUI de todo Chile (Reszka, 2017b). Se está a la espera de la renovación de las estadísticas de CONAF, debido a que en estos últimos datos citados no se encuentra información sobre último incendio ocurrido entre enero y febrero de 2017, por lo que se estima dichos porcentajes aumenten.

Castillo *et al.* (2011) dan a conocer en su trabajo que la zona de Valparaíso se caracteriza por una elevada ocurrencia de incendios forestales en sectores densamente poblados y, donde en los últimos 40 años, a pesar de los enormes esfuerzos desplegados por los organismos estatales encargados de la protección y combate contra incendios forestales, los medios informan sobre el sinnúmero de viviendas arrasadas por el fuego y los lamentables perjuicios sobre sus habitantes, incluyendo la pérdida de vidas.

Por otro lado, debe destacarse que en Chile, el pino radiata (especie de estudio) es una de las especies de árboles más utilizadas por la industria forestal. El alcance de plantaciones de la especie ha crecido rápidamente en las últimas décadas, cubriendo más de 2 millones de hectáreas, especialmente en las zonas mediterráneas del país (Becerra y Bustamante, 2008). Según CONAF, a partir de la superficie quemada por incendios forestales, el mayor daño corresponde a praderas y matorrales, y en menor escala se distingue, principalmente, el pino radiata (CONAF, 2016c).

El modelo que utiliza la CONAF para el pronóstico del grado de peligro de incendio (índice de grado de peligro – IGP) es en base a índices meteorológicos. Utiliza una ecuación de múltiples variables (temperatura del aire, humedad relativa, velocidad del viento, entre otras). En cuanto a los sistemas de detección que utilizan, se encuentran los sistemas de detección terrestre móvil, detección terrestre fija, detección aérea, detección con sistemas televisivos y, finalmente, por imágenes satelitales. Mas no se encuentra una relación *preventiva* basada en teledetección satelital y menos aún alguna relación entre dicha información y la espectrometría.

En un incendio forestal no solo se pierden árboles y matorrales, sino también hogares, fauna, fuentes de trabajo e incluso vidas humanas. Por tanto, si con una metodología se puede aportar aunque sea mínimamente en la prevención o gestión del riesgo de los incendios forestales, los favorecidos serán muchos. Desde el medio ambiente, las personas que viven en el sector, la flora y fauna, y hasta al propio Estado de Chile por las pérdidas económicas que los incendios generan (Chuvienco *et al.*, 2009), que, en efecto, se estiman en un promedio anual de US\$ 50 millones (UNESCO, 2012).

1.2. Objetivos

1.2.1 Objetivo general

Proponer una metodología y modelos estadísticos para estimar, indirectamente, con el empleo de índices espectrales, el contenido de humedad (FMC) de combustibles vivos de la especie *Pinus Radiata* a partir de información satelital e hiperespectral en la V Región de Valparaíso, Chile.

1.2.2 Objetivos específicos

1. Estudiar el estado del arte sobre el tema en cuestión: la situación actual de Chile y el resto del mundo en éste ámbito.
2. Estudiar y entender: (1) el procesamiento de imágenes satelitales y su uso práctico en materia de incendios forestales; y (2) la aplicación y funcionamiento de la espectrometría e instrumentos ópticos tales como espectrómetros.
3. Analizar muestras de vegetación viva (*pino radiata*) que se obtendrán en la Reserva Lago Peñuelas de la CONAF (V región, Valparaíso – Chile) en el laboratorio EC²G (UTFSM – Casa Central) con el fin de obtener el espectro de la vegetación y variables asociadas a la humedad del combustible vegetal.
4. Generar expresiones matemáticas para determinar el contenido de humedad como porcentaje de la biomasa (FMC) de las muestras recolectadas a partir de índices espectrales (tanto a nivel hiperespectral como satelital), y se evaluará su eficiencia estadística por medio del error medio cuadrático (RMSE – *Root Mean Square Error*).

1.3. Alcance de la investigación

La investigación que se llevará a cabo es de tipo experimental. En efecto, se manipularán muestras de vegetación viva (combustibles vivos) de la especie *Pinus Radiata* las cuales se obtendrán en los bosques de la Reserva Lago Peñuelas, ubicada en la Ruta 68 (kilómetro 89), Región de Valparaíso – Chile, coordenadas: 267.301 y 6.324.652, UTM huso 19 Sur. Cabe destacar que el día de recolección de las muestras será el día posterior al paso del satélite por temas de eficiencia. Más adelante se demostrará que, mientras se cumplan los criterios mínimos de recolección i.e hora, humedad relacionada a lluvias, entre otros, no debiesen existir mayores variaciones.

A cada pino (de donde se sacaron las muestras) se le guardará su respectiva ubicación geográfica por medio de un GPS. Para fines prácticos, todas las coordenadas del presente trabajo se realizarán en una proyección UTM (*Universal Transverse Mercator*) con datum WGS 84 (*World Geodetic System 1984*) huso 19 Sur. A su vez, a cada pino se le extraerá una cierta cantidad de hojas (agujas de pino), las cuales se dividirán para realizar los siguientes experimentos:

1. **Espectrometría:** La primera porción de las muestras irá al análisis del espectro de reflexión de la vegetación. Dicho estudio se realizará por medio de un espectrómetro que permite medir la reflectancia de las muestras a determinadas longitudes de ondas, con un rango espectral comprendido entre los 650 – 1.100 nm, lo que permitirá obtener diversos índices espectrales que estiman variables como la cantidad de humedad en el combustible (NDWI – *Normalized Difference Water Index*; WI – *Water Index*; NDII – *Normalized Difference Infrared Index*; MSI – *Moisture Stress Index*; etc), la cantidad de clorofila y carotenoides (Índice de Gitelson) y la vigorosidad de la vegetación (NDVI – *Normalized Difference Vegetation Index*; SAVI – *Soild Adjusted Vegetation Index*; entre otros).
2. **Fuel Moisture Content:** La segunda porción de las muestras se utilizará para determinar la humedad inmersa en la vegetación como porcentaje de la misma (FMC). En este estudio, lo primero consiste en obtener el peso fresco de las muestras, que se intentará sea lo más cercano a 5 gramos. Luego, esa misma cantidad de vegetación se secará en un horno (a 60°C por 24 horas) con el fin de obtener el peso seco de la muestra. Con dichas variables es posible calcular el contenido de humedad como porcentaje de agua dentro de la biomasa, o *fuel moisture content* (FMC [%]).

Una vez terminada la fase experimental, comenzará el análisis de los datos. Éste se enfocará en la obtención de la relación que existe entre los resultados obtenidos en el análisis espectral y de laboratorio con aquellos obtenidos de las imágenes satelitales por medio de índices espectrales existentes en la literatura. Sin embargo, surge un problema dado que el espectrómetro con el que se realizará el estudio abarca sólo una pequeña región del espectro óptico (entre los 650 y 1.100 [nm]), por lo que se hace necesario utilizar modelos de transferencia radiativa (PROSPECT) que permiten simular el espectro de reflexión entre los 400 – 2.500 nm en base a ciertos parámetros que se pueden obtener en laboratorio para ampliar el rango de estudio (por regiones de diversos índices espectrales).

Además, existen una serie de limitantes asociadas al estudio espectral y la recolección de muestras con respecto al clima. Primero, al trabajar con imágenes del dominio óptico pasivo del espectro electromagnético el problema se traduce en que si el día está nublado, no existirá información espectral en la imagen satelital. A su vez, el satélite Landsat 8 (el cual se utilizará para la investigación) posee una revisita (resolución temporal) de 16 días. Es decir, cada 16 días se tendrá una imagen del lugar esperado, por lo que si luego de esos 16 días está nublado, habrá que esperar 16 días más para poder ir a recolectar las muestras y así tengan consistencia con la información de las imágenes satelitales. Otra limitación son las lluvias, ya que si la vegetación está mojada, entonces tampoco sirve para trabajar las muestras en el laboratorio, dado que los resultados serían erróneos.

Cabe destacar que se cuenta con permisos por parte de la CONAF para ingresar a la Reserva Lago Peñuelas y recolectar las muestras. A su vez, las imágenes satelitales del satélite Landsat 8 son de libre acceso, posibles de descargar desde, por ejemplo, la plataforma *Earth Resources Observation and Science Center (EROS)* del *United States Geological Survey (USGS)*. Además, se cuenta con los permisos para trabajar en el laboratorio EC²G de la UTFSM – Casa Central y con los correspondientes instrumentos para el análisis.

El alcance a futuro radica en la obtención de variables asociadas al proceso de ignición de la especie bajo estudio a partir del análisis de la calorimetría de la vegetación. Este primer proyecto es, entonces, la primera fase, que consiste en determinar la factibilidad de estimar, indirectamente, el contenido de humedad de la vegetación como porcentaje de la misma (FMC) a partir de teledetección satelital, con la finalidad de luego poder, en un trabajo a futuro, estimar variables calorimétricas a partir de modelos estadísticos que involucren índices espectrales e información satelital.

Por último, el tiempo para realizar el proyecto se estima en 15 meses a partir de Marzo 2016.

2 | Estado del Arte

El presente capítulo se enfocará en realizar un recorrido bibliográfico de los temas que rondan en torno al trabajo en cuestión, que conlleva tanto citas de artículos científicos, conferencias científicas, libros, entre otros, con el fin de obtener un mayor conocimiento de los estudios que se realizarán en el proyecto, como también las bases que sustentarán el mismo.

La finalidad es establecer un aporte del proyecto para el mundo científico y un beneficio, a largo plazo, para la sociedad. Así, lo que se busca es contribuir con una recopilación de información bibliográfica que se pueda intersectar para entender más a fondo sobre los temas que involucran el proyecto y sobre la sinergia que éstos pueden tener para lograr la consecución de los objetivos planteados. Este estudio es la primera parte a realizar para un proyecto a largo plazo, que tiene que ver con la utilización de imágenes satelitales para explicar, en base a modelos estadísticos, una relación de variables calorimétricas con índices espectrales. Así, este trabajo es la base para lo que continúa a futuro.

2.1. Antecedentes y situación actual

El tema en cuestión trata de dos grandes puntos: Teledetección satelital e incendios forestales. A continuación, se realizará una situación actual de dichos puntos para Chile y algunos referentes mundiales. A modo de resumen, se puede ver la [Figura 2.1](#).

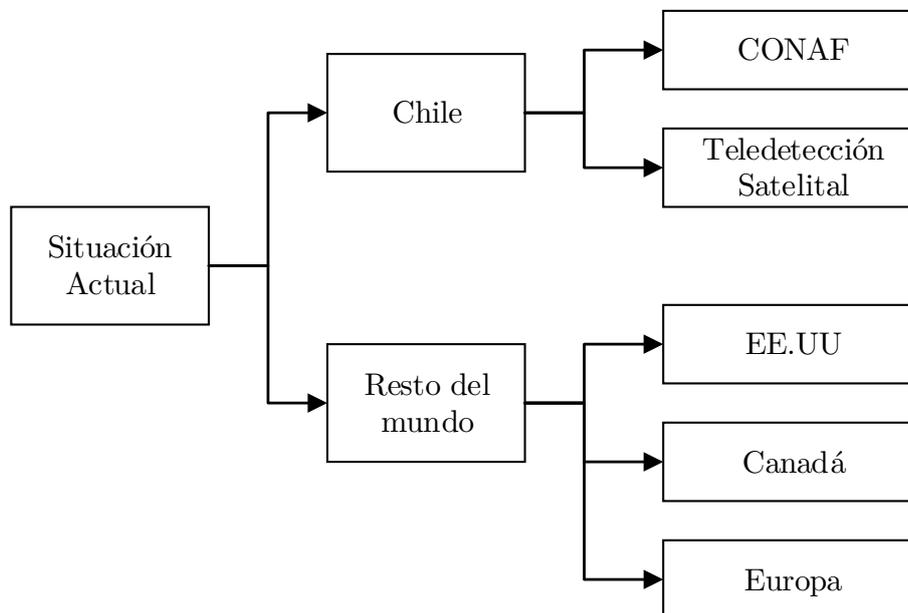


Figura 2.1: Esquema de la situación actual a analizar.

2.1.1 Chile

En Chile, los incendios forestales afectan miles de hectáreas de bosques, matorrales, pastizales y todo lo que habita en ellos. Es muy necesario y urgente que todos participen evitando que estos ocurran (CONAF, 2016c). La principal entidad encargada en materia de incendios forestales es la Comisión Nacional Forestal (CONAF), por lo que a continuación se hablará en breve de dicha institución y algunas responsabilidades que ésta debe llevar a cabo.

2.1.1.1 Comisión Nacional Forestal – CONAF

Para la totalidad de los puntos a tocar, la fuente a utilizar es la página web de la Comisión Nacional Forestal (CONAF, 2004, 2011). Los temas que se tocarán son:

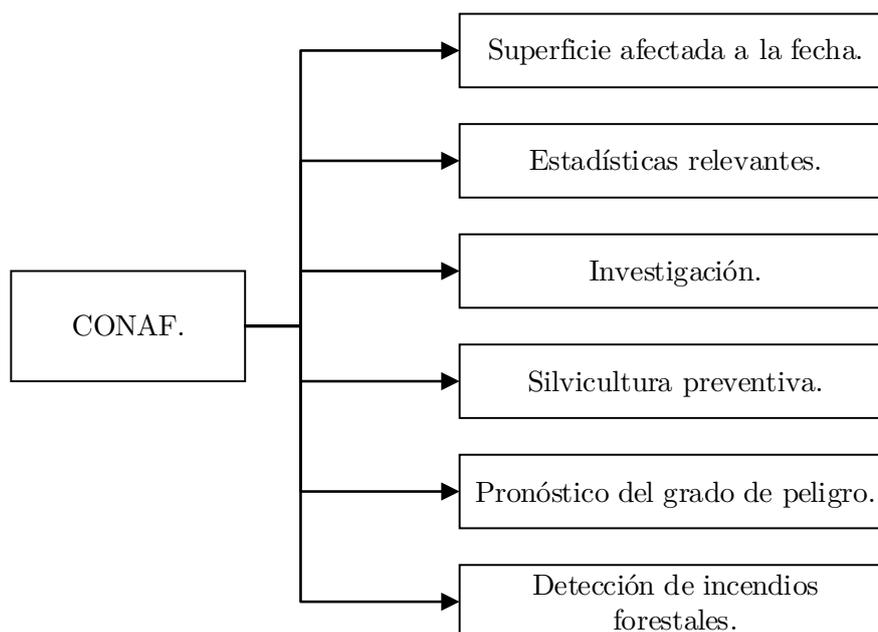


Figura 2.2: Mapa conceptual de los términos a tratar.

Fuente: Elaboración propia a partir de la información proporcionada en la página web de CONAF.

2.1.1.1.1 Incendios forestales en Chile

CONAF define un incendio forestal como un fuego que se propaga sin control en terrenos rurales. Como se dijo anteriormente en la [Sección 1.1 \(Justificación del tema\)](#) del [Capítulo 1](#), la principal fuente detonante de incendios forestales en Chile (y el resto del mundo) es la acción humana. Dentro de estos puntos los más relevantes son los descuidos o negligencias en las manipulaciones de fuentes de calor en presencia de combustibles vegetales. Pero, también existen las causas naturales, motivos que si bien son en baja proporción en Chile (0,3 % según CONAF, 2004), en otros países como España, llegan a ser alrededor de un 4 % de los incendios forestales (ICONA, 1995).

La superficie arrasada por incendios forestales en Chile, tiene una media de 46.000 hectáreas por período de incendios forestales (al 2011 –CONAF, 2011), valores que varían de 10.000 a 101.000 hectáreas. A su vez, en Chile operan dos sistemas de protección contra incendios forestales claramente definidos. Uno está por el sector forestal privado, donde se destacan las empresas forestales tales como: CELCO, Forestal Mininco, MASISA, Bosques Cautín, entre otras, que protegen con sus propios recursos más de un millón y medio de hectáreas de plantaciones forestales entre las regiones del Maule

y la Araucanía. Y, por otro lado, se encuentra el Estado de Chile, quién, por su parte, se centra en la CONAF que, en su calidad de servicio forestal nacional y entre sus variadas acciones, gestiona un programa de manejo del fuego para la protección contra incendios forestales en el país, tanto para resguardar al Sistema Nacional de Áreas Protegidas del Estado (SNASPE), sistema constituido por 36 parques Nacionales, 49 reservas nacionales y 15 monumentos naturales, como para contribuir a la proyección de terrenos rurales privados de medianos y pequeños propietarios con la finalidad de proteger la integridad de las personas y sus bienes.

I. Superficie afectada a la fecha (Febrero 2017)

La CONAF cuenta con un avanzado sistema que se encuentra en su página web (CONAF, 2015a), el cual cuenta con información que se va modificando cada 15 minutos y presenta el número de incendios a la fecha y la superficie afectada en hectáreas en la presente temporada, que va del 1 de julio al 30 de Junio del año siguiente. Se puede observar que a la fecha de 13 de Junio de 2015, la segunda región con más incendios forestales (casi terminando el período u ciclo de la temporada 2014–2015), es la V Región de Valparaíso con 806 incendios. Ahora bien, cabe destacar que si bien se lleva el segundo lugar en cantidad de incendios, para la superficie dañada total se lleva el puesto número 6 en dicha temporada, donde bajó un 46 % en comparación a la temporada pasada (2013–2014), algo claramente lógico si se contrasta con la envergadura que tuvo el “Gran incendio de Valparaíso” el 12 de abril de 2014. Por otro lado, cabe destacar el daño ocasionado más recientemente entre enero y febrero 2017, donde se quemaron al rededor de 403.596 hectáreas al 14 de febrero 2017 (Ministerio de Agricultura, 2017). De esta forma, es importante mencionar que las cifras claramente cambiarán (en cuanto a los promedios de áreas quemadas, etc), pero se está a la espera de información por parte de las autoridades para información más precisa y detallada.

II. Estadísticas relevantes.

En cuanto a las estadísticas que la CONAF presenta, la mayoría se basan en análisis de causalidades de los incendios, superficies afectadas y cantidad de incendios. Por ejemplo, entre los años 1990 – 2015 se puede apreciar una media de 45.480 hectáreas de superficie afectada por incendios forestales anualmente en Chile (ver la Figura 2.3 para información visual).

III. Investigación.

Con el motivo de presentar la mejor fuente de información posible y confiable, la CONAF realiza estudios sobre el comportamiento de las personas u grupos objetivos, teniendo en cuenta que el humano es el principal causante de incendios forestales. Por otro lado, CONAF cuenta con brigadas de determinación de las causalidades de incendios (BRIDECA), con el objeto de establecer las causas específicas que dieron origen a éstos.

IV. Silvicultura preventiva.

La silvicultura se define como el “1. cultivo de los bosques o montes, 2. Ciencia que trata de este cultivo” (RAE, 2015). La CONAF lo define como la modificación, ordenamiento o eliminación de la vegetación viva o muerta y de los residuos y desechos vegetales para evitar que se produzca un incendio forestal o, si se inicia, retardar su propagación y mitigar los daños.

V. Pronóstico del grado de peligro.

• Definición del grado de peligro.

Es la combinación de factores ambientales, fijos y variables, que determinan la probabilidad de inicio de incendios forestales y el posterior comportamiento del fuego. Dentro de los factores fijos o estáticos (que no cambian o lo hacen muy lentamente) se encuentra la topografía (pendientes), y el tipo, tamaño y especie de vegetación presente. Los factores variables son aquellos que se modifican en función del tiempo, inclusive diariamente. Aquellos son el tiempo atmosférico y el contenido de humedad de la vegetación (CONAF, 2015c). Aquellos son los valores que adquiere el Índice de Grado de Peligro (IGP) de la

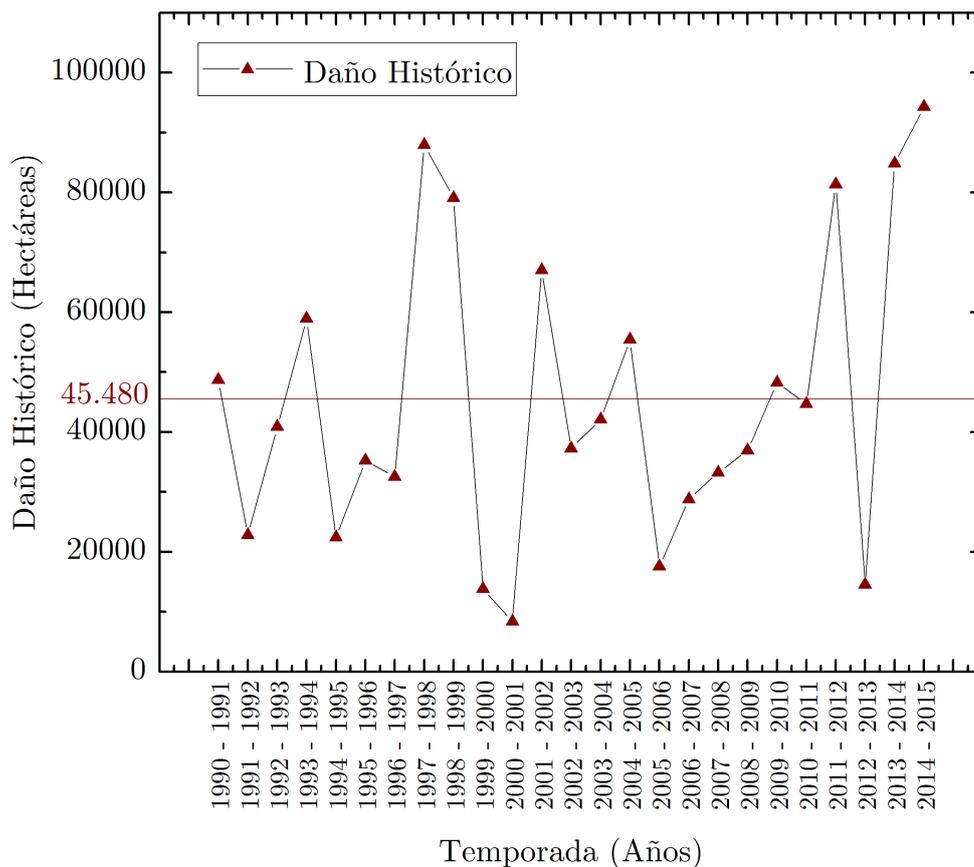


Figura 2.3: Superficie afectada por incendios forestales entre los años 1990 y 2015.

Fuente: Elaboración propia a partir de CONAF (2016b).

CONAF. La expresión u resultado de éste índice es una medición del riesgo asociado a incendios forestales en una escala de: bajo, medio o extremo. Lo anterior es en base a una fórmula lineal de primer grado (Ecuación 2.1).

$$Y = 17,7 + 1,17T - 0,44HR + 0,35VV + 18,7FE - 0,27FS \quad (2.1)$$

Donde,

Y = Probabilidad de ocurrencia diaria, escala de 0 - 100.

T = Temperatura del aire en °C.

HR = Humedad relativa [%].

VV = Velocidad del viento [nudos].

FE = Factor de estacionalidad de la vegetación, por tabla, de 1 a 3.

FS = Factor de sequedad, por tabla de 0,5 a 70.

Los datos meteorológicos pueden ser del momento, o bien pronosticados. De esta forma se puede obtener un IGP pronóstico para realizar la gestión del riesgo. La idea del IGP es poder tener un índice para información pública y de prevención de incendios forestales.

VI. Detección de incendios forestales.

a. Sistemas de detección:

La CONAF utiliza variados métodos para la detección de incendios forestales. Estos se resumen en la [Figura 2.4](#) y se explican brevemente a continuación.

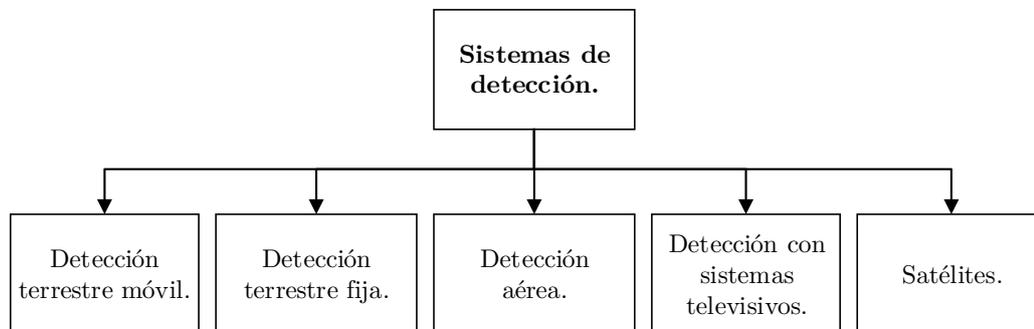


Figura 2.4: Esquema de los sistemas de detección.

Fuente: CONAF (2015b).

- **Detección terrestre móvil.**
Corresponde al desplazamiento de vigilantes en un área determinada, ya sea por un medio de transporte o a pie.
- **Detección terrestre fija.**
Es la modalidad de detección de **mayor aplicación** en Chile. Se basa en la visión de un observador desde estructuras metálicas o de madera de 15 a 30 [m] de altura, denominadas torres, o bien casetas de menor altura llamadas puestos de detección.
- **Detección aérea.**
Se basa en la utilización de aviones, generalmente mono-motores de ala alta, para detectar incendios desde el aire. El piloto es acompañado por un observador, quien es el que realiza propiamente la verificación del terreno.
- **Detección con los sistemas televisivos.**
Se basa en la utilización de cámaras de televisión que transmiten una señal por microondas hasta las pantallas de puesto de mando. Las cámaras se instalan en torres ubicadas en la cumbre de cerros, barriendo áreas en 360°, o bien, instaladas en el exterior de aviones e, inclusive, en aviones no tripulados (UAV – *Unmanned Aircraft Vehicle*).
- **Satélites.**
Existen áreas en el mundo donde, debido a la carencia de organizaciones de protección contra incendios forestales, o de sistemas de detección, donde la única posibilidad de conocer lo que ocurre es utilizando imágenes satelitales de órbita baja. Tales son los casos de los satélites gemelos Aqua y Terra, los cuales son satélites idénticos que difieren en la dirección de su órbita.
Sin embargo, para detección de incendios esta modalidad es lenta, dado el tiempo entre pasadas del satélite.

2.1.1.1.2 Región de Valparaíso

La región de Valparaíso ha sido la electa para realizar el presente proyecto. La razón de esto es dado la cantidad de incendios, la cantidad de áreas quemada y la vulnerabilidad al riesgo que existe por tener una alta relación entre zonas rurales y urbanas, de la mano con que en dichas zonas, denominadas WUI (*Wildland–Urban Interface*), presentan una mayor probabilidad de ignición al coexistir, como se dijo, la infraestructura humana con la vegetación (Castillo *et al.*, 2009; Radeloff *et al.*, 2001; Reszka y Fuentes, 2014). A su vez, a ésta le corresponde una participación de un 15 % de los incendios forestales y un 15,2 % de la superficie afectada a nivel nacional (CONAF, 2011).

Los incendios forestales en la Región de Valparaíso.

i. Características de la región.

La región de Valparaíso se localiza entre los paralelos 32°02' y los 33°57' de Latitud Sur, y desde el meridiano 70° al 72° de Longitud Oeste. Por el lado oeste limita con el Océano Pacífico, y por el este limita con Argentina, en la Cordillera de los Andes. Según el Instituto Nacional de Estadísticas de Chile, se estima que la V Región de Valparaíso cuenta con un total de 1.842.880 habitantes, equivalente al 10,2 % de la población total de Chile (INE, 2016), con un total de 107,3 habitantes por km² al año 2010 (INE, 2010, pág. 96). La región de Valparaíso está conformada por 7 comunas: Valparaíso, Casablanca, Concón, Juan Fernández, Puchuncaví, Quintero y Viña del Mar.

ii. Número y superficie afectada por incendios forestales en la región.

Entre los años 2002–2011 se produjeron en la V Región 922 incendios forestales, los cuales afectaron una superficie de 7.076,7 hectáreas. Dentro de la V Región, la provincia de Valparaíso presenta el mayor número de incendios entre los años 2002 y 2011. Con un total de 359 que representan el 38,9 % del total, con una superficie afectada de 2.283,3 hectáreas que representan el 32,3 % del total de la región (CONAF, 2004).

iii. Comunas prioritarias en la región.

Las comunas de Valparaíso y Viña del Mar, concentran gran parte del problema (83,5 % de la ocurrencia de incendios forestales de toda la región – CONAF, 2004).

Por otro lado, no está demás destacar que CONAF ha definido el concepto de áreas homogéneas de riesgo de incendio forestal, que corresponden a zonas en donde es más posible que se produzcan incendios forestales. Estas zonas son el resultado del análisis de variables que inciden directamente en el riesgo de incendios forestales que entregan información para diseñar las medidas de prevención. Así, cada área tiene un determinado código asignado. CONAF diseñó 23 códigos de tipos de áreas homogéneas asociados al SNASPE (Sistema Nacional de Áreas Silvestres Protegidas del Estado) para la Región de Valparaíso. La tabla con los códigos, su respectivo atributo y superficie se puede apreciar en la Tabla A.1 del Anexo A. Por otro lado, en el manual de la Comisión Nacional Forestal (CONAF, 2004, pág. 62), hay una imagen de la comuna de Valparaíso delimitada con los diversos códigos de áreas homogéneas. De esta forma es posible determinar que las áreas afectadas en el incendio del 12 de Abril de 2014, “El Gran incendio de Valparaíso”, los principales códigos son el AH9 y el AH18, es decir, sectores SNASPE y sectores cercanos a poblados, respectivamente, donde existe una alta probabilidad de ocurrencia de incendios forestales.

2.1.1.2 Teledetección Satelital en Chile.

Chile no se ha quedado atrás en el rubro aeroespacial. Si bien aún no es un tema amplio para el país, se viene experimentando desde el año 1995 con el lanzamiento del satélite FASat-Alfa, primer satélite chileno enviado al espacio.

En esta sección se comentará sobre las misiones que ha lanzado Chile al espacio, una breve descripción de éstas y algunas aplicaciones enfocadas al último: el SSOT.

- **FASat - Alfa.**

Dentro de los objetivos generales del proyecto FASat–Alfa se encuentra el obtener experiencia científica y tecnológica básica necesaria para continuar hacia pasos más avanzados y el monitoreo de la capa de ozono. Las características del FASat–Alfa se pueden ver en la [Tabla B.1](#) del [Anexo B](#).

Si bien el resultado final fue nulo para el primer satélite chileno, por la falla en el sistema de desacople del satélite con el Sich–1, se abrieron las puertas a las oportunidades y a la entrada de nuevas tecnologías en materias aeroespaciales.

- **FASat – Bravo.**

Más tarde (luego de casi 3 años) se lanza el satélite FASat–Bravo, el segundo satélite chileno, que si bien tenía las mismas características que el FASat–Alfa, éste último obtuvo resultados exitosos ([Underwood et al., 2003](#)). Las características de este satélite se pueden apreciar en la [Tabla B.2](#) del [Anexo B](#).

Luego de 5 años de haber terminado la misión del FASat–Bravo, se comienza a pensar en la construcción de un nuevo satélite, el FASat–Charlie, más conocido como SSOT.

- **FASat – Charlie: SSOT**

En Marzo de 2006, se adjudica la licitación a EADS–Astrium para la construcción del satélite SSOT (*Sistema Satelital de Observación Terrestre*), con una inversión aproximada de \$US 72 millones, punto que no resultó. Así, se llama a una licitación internacional el 25 de noviembre de 2007, donde EADS–Astrium terminó, nuevamente, adjudicándose la licitación. El 7 de agosto de 2008, el Ministerio de Defensa de Chile y la empresa EADS–Astrium firman el contrato para la construcción del SSOT ([Trujillo, 2015](#)). En la [Tabla B.3](#) del [Anexo B](#) se pueden apreciar las características del satélite. El contrato constó de los siguientes términos:

- Estación terrena.
- Equipamiento para la interpretación de imágenes.
- Programa de entrenamiento de técnicos chilenos.
- Satélite SSOT.

Después de una década de haber finalizado la misión FASat–Bravo, el SSOT es lanzado al espacio adosado a un cohete Soyuz. El SSOT es un micro-satélite, como se puede ver en la [Tabla B.3](#), que consta de una resolución espacial de 1,45 [m] en el canal pancromático y 5,80 [m] en la región multi–espectral.

Los encargados de la telemetría (manejo de bandas X y S) es el *Grupo de Operaciones Espaciales* (GOE), de la Fuerza Aérea de Chile (FACH). Entre sus operaciones, se destacan los Ciclos de la Misión y los Ciclos de Producción ([G.O.E, 2015b](#)), ver [Figura 2.5](#). A continuación se detallarán algunas de las aplicaciones mediante datos obtenidos de imágenes del SSOT. Cabe destacar que el satélite se ha utilizado para, por ejemplo, identificar zonas afectadas por diversas catástrofes naturales ([Rivera, 2012](#)).

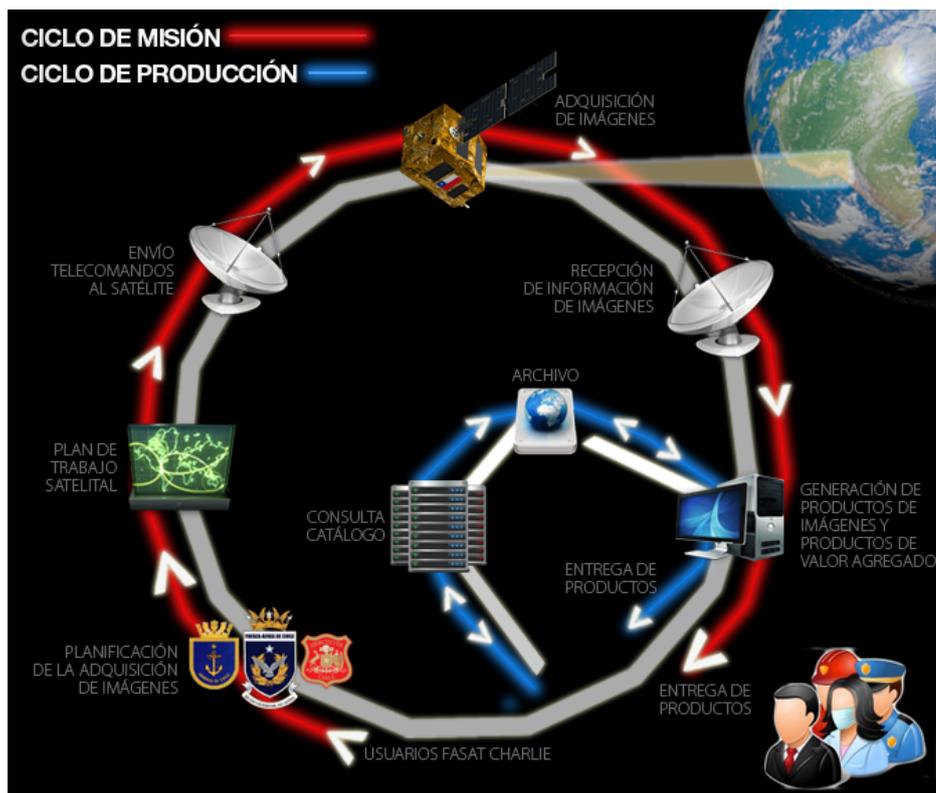


Figura 2.5: Ciclos de misión y producción del G.O.E.

Fuente: G.O.E (2015b).

i. Agricultura de precisión.

La agricultura es una de las actividades más relevantes dentro de la economía chilena. En dicho contexto, la posibilidad de contar con información satelital que pueda aportar a su explotación resulta muy beneficioso para el desarrollo de la nación.

Un ejemplo de lo anterior es la posibilidad de efectuar un monitoreo constante a los diferentes tipos de cultivos, a fin de tomar decisiones de modificación en la distribución de fertilizantes o regadío. Lo anterior es factible debido a que cuando se adquiere la imagen de un sector determinado, la función de los sensores del satélite entran en acción, es decir, captar la energía reflejada. Si el patrón de reflectancia de dicho cultivo es conocido, se puede estimar con «certeza» la cantidad de vegetación y la actividad de la clorofila. Así, lo anterior permite mantener un seguimiento y control de la vegetación (G.O.E, 2015a).

Como se puede observar en la Figura 2.6, por medio de imágenes satelitales es posible determinar zonas donde hay vegetación abundante (vigorosa) y zonas con problemas de agua u clorofila. Esto se puede hacer a través de diversos índices espectrales de vegetación, entre ellos el NDVI (*Normalized Difference Vegetation Index*), índices que se verán más adelante (ver la Sección 2.2.4).

ii. Control y prevención de inundaciones.

El hecho de poder adelantarse a los fenómenos naturales es, sin lugar a dudas, una herramienta muy útil en el contexto de Chile. Así, una de las características del SSOT es el apoyo a la gestión de prevención y control de inundaciones.

Las imágenes satelitales permiten construir simulaciones de las áreas potencialmente inundables, con la finalidad de poder adoptar medidas preventivas, y en caso de ocurrencia, que se puedan tomar las medidas pertinentes para la evacuación, por ejemplo. En este ámbito se destacan los mapas de riesgo de inundaciones y sus representaciones de la vulnerabilidad y

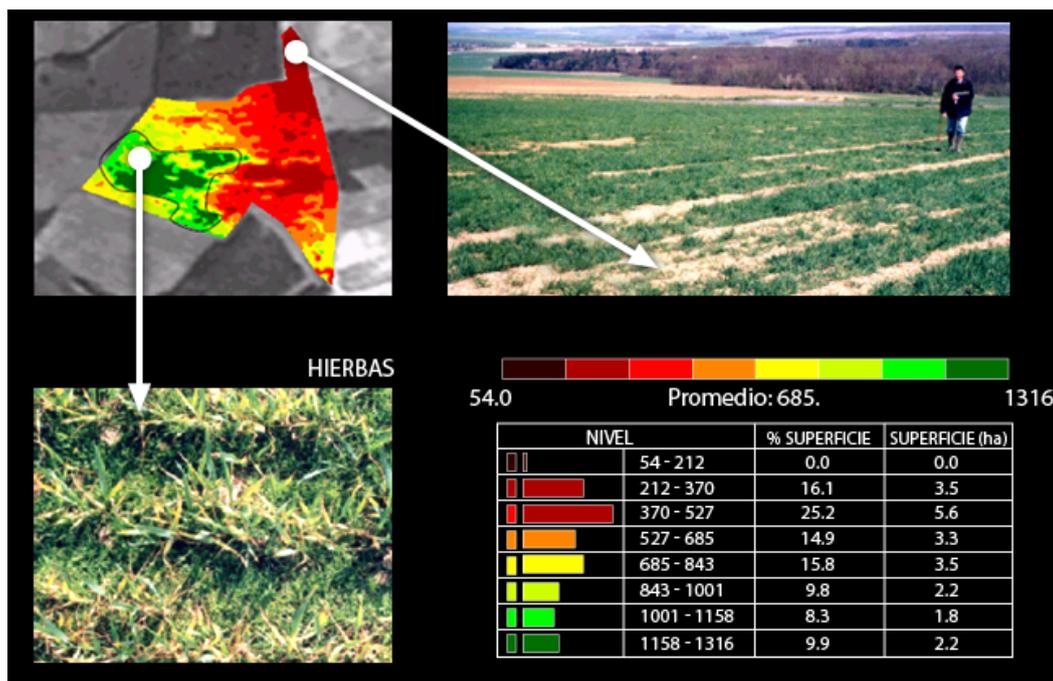


Figura 2.6: Agricultura de precisión con imágenes satelitales.

Fuente: G.O.E (2015a).

el cómo aportan las nuevas tecnologías para la gestión, trabajo que Masgrau (2004) realizó.

iii. Control de erupciones volcánicas.

En el caso de Chile, la realidad geográfica exige un especial cuidado en los aspectos relacionados con la gestión de emergencias volcánicas. Así, el contar con imágenes satelitales multi-espectrales (XS), como las que provee el SSOT, permiten, entre otras cosas, identificar el flujo de lava y, de esta manera, apoyar a la gestión de la emergencia por parte de las autoridades. Ver Figura 2.7.

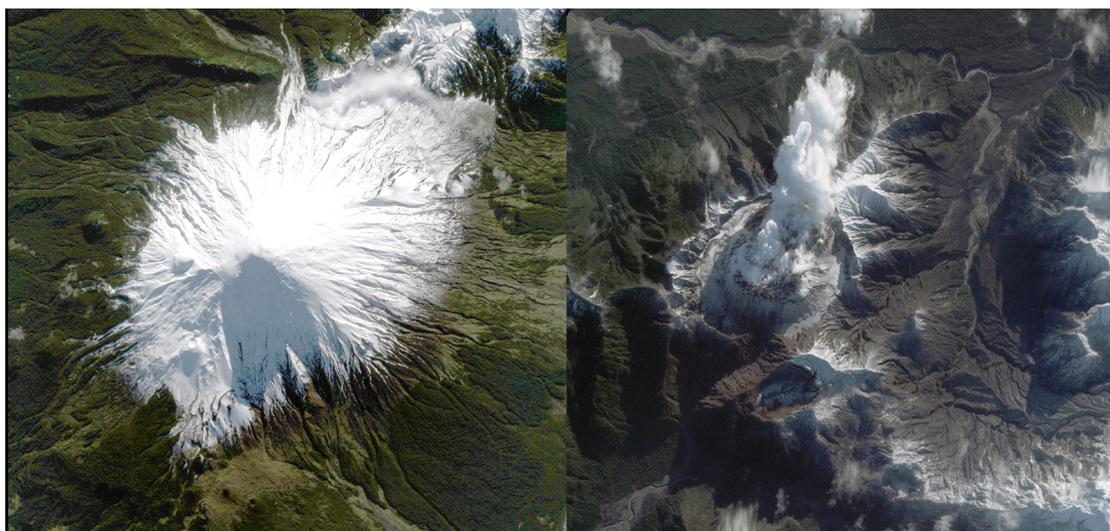


Figura 2.7: Gestión de emergencias volcánicas con imágenes satelitales

Fuente: G.O.E (2015a).

iv. Control de incendios forestales.

La resolución espacial del FASat–Charlie también permite apoyar a la gestión y control

de grandes incendios forestales, de manera tal de entregar la alarma en caso de un inicio, y luego cooperar en la gestión de la extinción del mismo en base a la información de cobertura que se pueda obtener.

Este punto es de suma relevancia para el trabajo, ya que se puede observar la falta de uso del satélite para investigaciones más acabadas en relación a la prevención de incendios forestales. Es decir, para incendios forestales su uso es enfocado en acciones correctivas. El SSOT cuenta con la tecnología necesaria para realizar estudios tan acabados como los que se han hecho con Landsat (Chuvienco *et al.*, 1998, 2002) o Modis (Hantson *et al.*, 2013; Zhang *et al.*, 2011a), de la USGS (*United States Geological Survey*) y NASA (*National Aeronautics and Space Administrations*), respectivamente, para la detección de incendios forestales mediante análisis de índices de vegetación, humedad del combustible, entre otros. Por medio del SSOT es posible contar con imágenes como las que se ven en la [Figura 2.8](#) y es factible determinar los mismos índices de satélites como Landsat o Modis (Aqua [EOS-PM 1] y Terra [EOS-AM 1]) que son satélites que cuentan con una plataforma de imágenes de libre acceso.

En cuanto a la [Figura 2.8](#), la imagen de la izquierda representa a una imagen en color verdadero (combinación de bandas RGB), mientras que la de la derecha una imagen en “falso color”, donde se resalta en tonalidades rojas la vegetación (utilizando el canal infrarrojo). Así, donde el rojo adquiere tonalidades más intensas, más vigorosa es la vegetación.

Por otro lado resulta interesante analizar la imagen que alcanzó a capturar el SSOT del “Gran Incendio de Valparaíso” (ver la [Figura 2.9](#)). En base a este tipo de imágenes es que se puede ayudar a la toma de decisiones de catástrofes naturales, labor que ejerce el Centro de Información de Recursos Naturales (CIREN) al momento en que la ONEMI decreta emergencia y activa el llamado *International Charter Space and Major Disasters*, que es un acuerdo internacional para compartir información en caso de catástrofes (este tema se ahondará en mayor profundidad en la [Sección 2.1.1.2.1](#)).



Figura 2.8: Incendios en la Región del Bío-Bío, Chile.

Fuente: G.O.E (2015a).

v. Cartografía.

Contar con imágenes propias del SSOT, con una resolución espacial pancromática menor a 2 [m], permite construir y actualizar la información geográfica del país. A modo de ejemplo, se puede ver la [Figura 2.10](#).



Figura 2.9: Captura del “Gran incendio de Valparaíso” por parte del SSOT el día 13 de abril de 2014.
Fuente: TVN (2014).

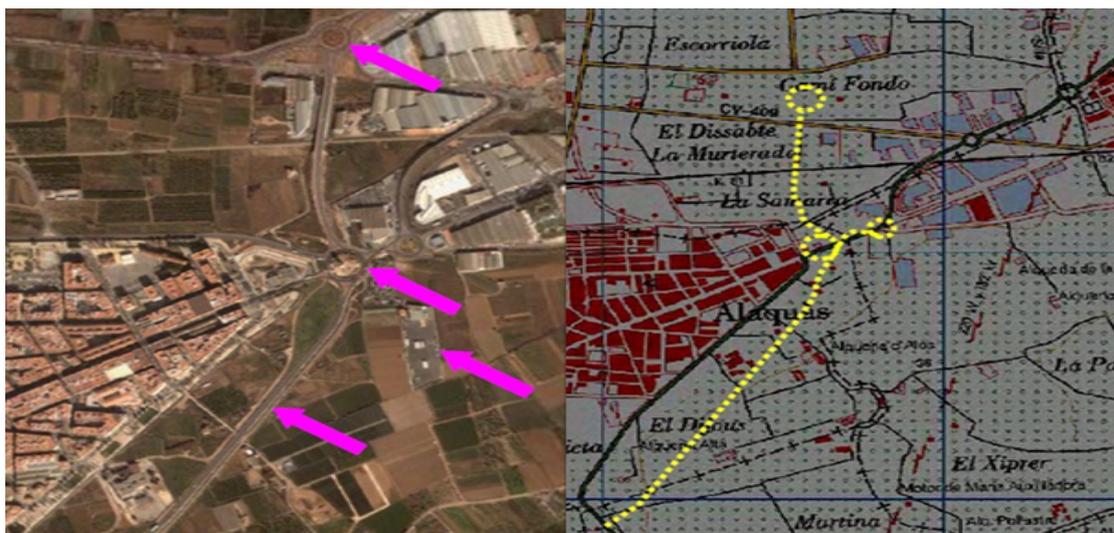


Figura 2.10: Generación y actualización de bases cartográficas empleando imágenes satelitales.
Fuente: G.O.E (2015a).

vi. Control de crecimiento urbano.

El crecimiento explosivo de los núcleos urbanos en el último tiempo es un problema que requiere de un seguimiento y controles eficientes. Para esto, las imágenes satelitales son de gran utilidad, puesto que permiten mantener un monitoreo constante de un sector determinado, a fin de evaluar los cambios de construcciones. La forma de realizarlo es tan simple como hacer una resta de imágenes nuevas versus las antiguas, dicho método se denomina: “*Detección de cambios*” (Yuan *et al.*, 2005).



Figura 2.11: Control de crecimiento urbano con imágenes satelitales.

Fuente: G.O.E (2015a).

vii. Defensa.

Las características propias del SSOT, permiten – también - proveer imágenes satelitales para la defensa nacional.

En este campo de acción, se pueden apoyar los procesos de inteligencia, de alarma estratégica, de control y evaluación de daños, control de fronteras, entre otros.

viii. Aporte al desarrollo del país.

“Hoy en día no es novedad que aquellos países que, durante las últimas décadas han logrado resultados significativos en su crecimiento económico, han basado sus estrategias en la capacidad de innovación y producción de tecnología de vanguardia, de manera autónoma, logrando así el esperado desarrollo e incluso superando cualitativamente a los ya desarrollados” (G.O.E, 2015a).

2.1.1.2.1 Entidades especializadas

Existen diversas entidades que se especializan en el procesamiento de imágenes satelitales. En el caso de Chile se identifican dos grandes, el Servicio Aerofotogramético (SAF), dependiente de la Fuerza Aérea de Chile (FACH), y el Centro de Información de Recursos Naturales (CIREN), dependiente del Ministerio de Agricultura de Chile.

i. SAF.

Las imágenes obtenidas del SSOT, por medio de los telecomandos realizados por el GOE, son procesadas por el SAF. En este punto, el SAF es fundamental para las operaciones del GOE, ya que éste tiene como misión el interactuar con los clientes para las necesidades que estos tengan y, de esta forma, realizar la telemetría (comunicación) con el satélite para establecer los telecomandos de las necesidades a satisfacer (SAF, 2015; Trujillo, 2015). En términos simples, el SAF no solo procesa imágenes del SSOT para el GOE, sino que también procesa imágenes para sus clientes. Los productos que el SAF ofrece son:

- Información vectorial.
 - Data vectorial (planimetría de polígonos).
 - Data con atributos (Capas de información).
- Basado en imágenes.
 - Imagen aérea impresa.
 - Imagen aérea digital.
 - Imagen satelital.
 - Mosaico de imágenes, entre otras.
- Representación cartográficas.
 - Capas de red vial.
 - Capas de límites comunales.
 - Capas de cursos de agua.
 - Capas de curvas de nivel, entre otras.
- Productos de elevación.
 - Utilización de sensor activo (LIDAR) para generación de modelos digitales de elevación y nubes de puntos.

ii. CIREN

El centro de información de recursos naturales es un instituto tecnológico que brinda servicio de apoyo al Ministerio de Agricultura de Chile (MINAGRI) que proporciona información de valor de los recursos naturales renovables del país. En la actualidad, CIREN lidera acciones para enfrentar nuevos desafíos en el área espacial, realizando una importante labor en el procesamiento e interpretación de imágenes satelitales vinculadas a la agricultura, a los recursos naturales y a los desastres naturales del país (CIREN, 2016).

Dentro de CIREN se encuentra la Gerencia de Geomática, y dentro de ésta se encuentra la “Subgerencia de Procesamiento de Imágenes y Modelamientos”, en dicha área se procesan las imágenes satelitales para las distintas labores que la institución realiza.

Ante la ausencia de una agencia aeroespacial, la ONEMI (Oficina Nacional de Emergencias de Chile) es la encargada de activar el llamado *International Charter and Major Disasters*, que es un acuerdo internacional de acceso universal que busca contribuir en la gestión de desastres poniendo a disposición de los estados/comunidades afectadas información aeroespacial de la zona. Así, CIREN es el encargado de procesar toda esta información con el fin de generar productos para la toma de decisiones de los organismos pertinentes.

A continuación se presenta el proceso del *charter* internacional para el caso de CIREN (ver Figura 2.12).

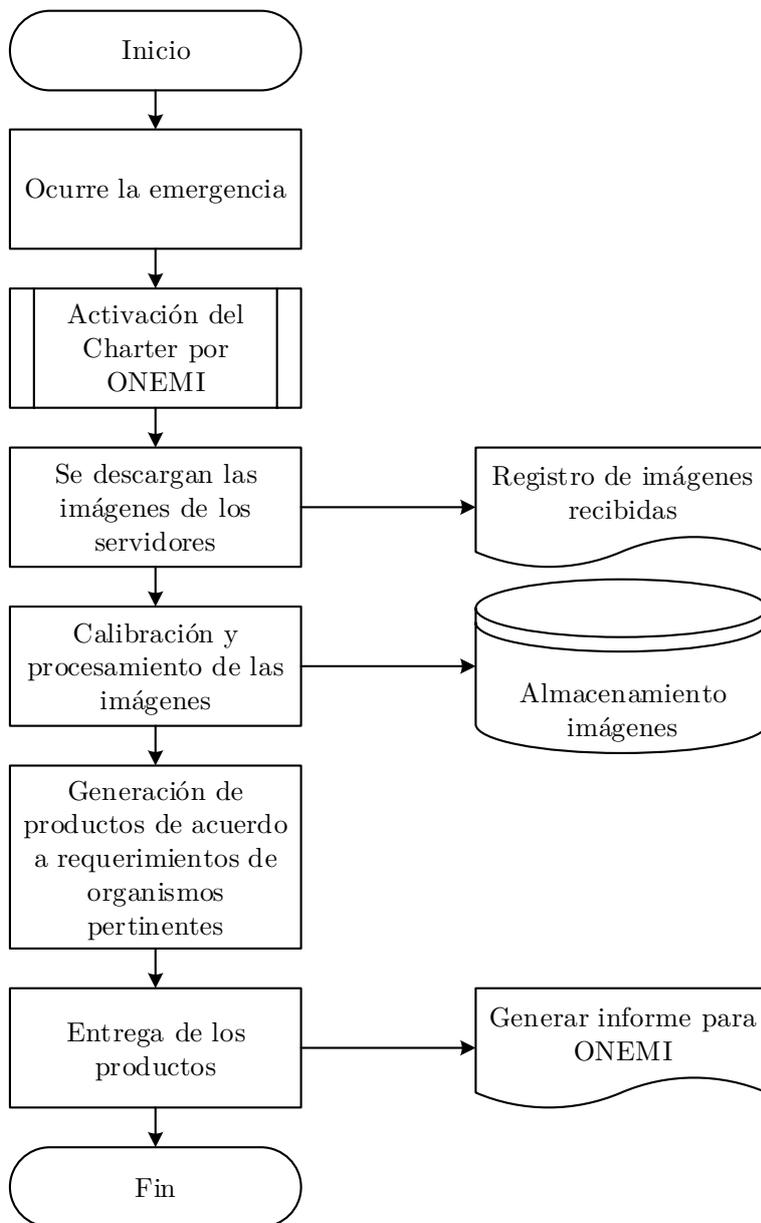


Figura 2.12: Proceso del *International Charter & Major Disasters* por parte de CIREN.

Fuente: Elaboración propia; se realizó la práctica profesional en la institución.

La finalidad de esta situación actual en Chile es dar a conocer la utilización de la teledetección satelital, donde se puede observar que existen diversos usos y aplicaciones, no solo por medio de imágenes del SSOT, sino que también de otros sensores/satélites. Es importante recalcar la ausencia de estudios u aplicaciones para la prevención de incendios forestales por medio de estas tecnologías. A continuación se realizará un breve análisis de la situación actual de países desarrollados en el tema en cuestión.

2.1.2 Resto del mundo.

El objetivo de la presente sección es estudiar como se encuentran países desarrollados en el ámbito de la utilización de tecnologías aeroespaciales para la prevención de incendios forestales. A continuación se analizarán factores como los índices de EE.UU, Canadá y Europa para lo que es la prevención del riesgo de incendios.

2.1.2.1 EE.UU.

Luego de la puesta en órbita de los satélites de observación Sputnik I y II, Estados Unidos no se quedó atrás. Lanzaron su primer satélite, el Explorer 1, en el año 1958 (NASA, 2015b). Desde entonces, su carrera aeroespacial no ha hecho más que crecer exponencialmente. EE.UU cuenta con una amplia gama de satélites de teledetección y, por supuesto, con una entidad dependiente del USDA (*United States Department of Agriculture* – Departamento de Agricultura de los Estados Unidos) la cual es el U.S Forest Service (Servicio Forestal de Estados Unidos – FS). Esta entidad cuenta con una gran cantidad de experiencia, estudios y aplicaciones para todo el país en materia de incendios forestales. Es más, el *Forest Service* cuenta con el programa FCCs (*Fuel Characteristic Classification System*) que identifica los sectores con mayor probabilidad de ocurrencia de incendios. El FCCs predice el comportamiento del fuego en la superficie, incluyendo la intensidad de las reacciones, el largo de la llama y la propagación del fuego (*rate of spread*) basado en un estándar de comparación y de condiciones ambientales. Así, el FCCs es parte de los 13 sistemas originales de predicción del comportamiento del fuego (*Fire Behavior Prediction System*) y uno de los 40 de estandarización de los modelos de combustibles (*Standard Fuel Models*) (Finney *et al.*, 2010; Scott y Burgan, 2005; USDA-FS, 2015b).

Adicionalmente, el *Forest Service* cuenta un subsector que se llama RSAC (*Remote Sensing Applications Center* – Centro de aplicaciones de sensores remotos), donde uno de sus programas y servicios es el desarrollo de aplicaciones (*Application Development*) donde éste provee aplicaciones de desarrollo para mejorar la calidad y predictibilidad de la información geoespacial producida por sensores remotos en el ámbito forestal, detecciones de cambio y monitoreo de aplicaciones (USDA-FS, 2015a).

También, existe una dependencia del *Forest Service*, que es el WFAS (*Wildland Fire Assessment System* – Sistema de Gestión de Incendios Forestales) (USDA-FS, 2015c). WFAS es una interfaz que predice para siete días el peligro de incendios forestales por medio de la NDFD (*National Digital Forecast Database*), una interfaz digital de predicción a nivel nacional.

Por otro lado, EE.UU cuenta con un índice de peligro de incendios forestales: NFDRS (*National Fire Danger Rating System* – Sistema de clasificación nacional de peligro de Incendios, Bradshaw *et al.*, 1983; Cohen y Deeming, 1985), donde su principal función es la prevención de dichos eventos. El NFDRS (ver Figura 2.13) evalúa la probabilidad de que se produzca un incendio forestal en un momento determinado y proporciona pautas sobre el posible desarrollo del mismo, pero sin predecir con precisión cual será el comportamiento del fuego (Salas y Cocero, 2004). El NFDRS está compuesto por diversos índices que evalúan los distintos componentes de riesgo a lo largo de todo EE.UU, basándose en múltiples tipos de información como, por ejemplo, los modelos de combustible, la humedad del combustible, las pendientes, los vientos, la actividad humana, la actividad tormentosa, entre otras.

Como se puede observar en la Figura 2.13, el NFDRS supone tres tipos de índices de ocurrencia de incendios forestales, los cuales son: los de origen humano, la actividad tormentosa y el contenido de humedad de los combustibles. Los dos primeros son en base a estadísticas de bases de dato del gobierno de los Estados Unidos. También, el NFDRS cuenta con un índice de combustión, el cual se obtiene mediante las componentes de propagación y de liberación de energía, que valora la dificultad de extinción del incendio mediante la velocidad de propagación, la estimación de la longitud de la

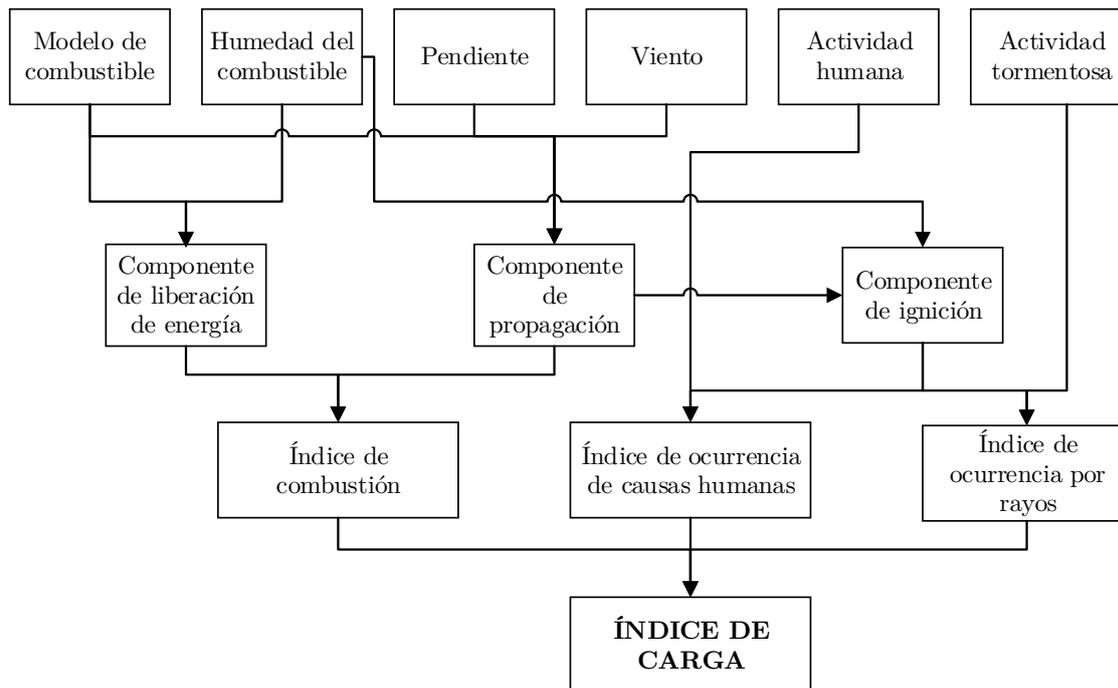


Figura 2.13: Esquema del índice NFDRS Estadounidense.

Fuente: Salas y Cocero (2004).

llama y la intensidad del frente de avance del incendio (Salas y Cocero, 2004).

Como producto final del NFDRS se tiene el índice de carga, el que se obtiene mediante la combinación de los índices de combustión, de ocurrencias de causas humanas y de ocurrencias por actividad tormentosa. Éste índice final adquiere un valor entre 0 y 100 informando, globalmente, sobre un incendio. Un valor alto puede significar una alta probabilidad de incendio o la dificultad de extinción del mismo.

Cabe destacar que Burgan (1988), actualizó el NFDRS incluyendo el índice de Keetch y Byram (1968), que cuantifica los efectos de la sequía a largo plazo. También, se modifican los modelos de humedad del combustible vivo, así como los 20 modelos de combustible definidos originalmente. Y, más adelante (años 90) se introdujo el uso de las imágenes satelitales en el sistema, con el fin de realizar un seguimiento del estado de la vegetación viva (Burgan y Hartford, 1993; Burgan *et al.*, 1996), además del uso de datos meteorológicos de intervalo horario, que fue posible gracias al aumento de la red de estaciones automáticas (Salas y Cocero, 2004).

Pese a todo lo que involucra el NFDRS, éste no considera el daño potencial de los posibles espacios afectados, es decir, la vulnerabilidad (Salas y Cocero, 2004).

2.1.2.2 Canadá.

Los primeros sistemas de predicción de peligro de incendio forestal surgieron en Canadá y EE.UU, que comenzaron sus investigaciones a finales de 1920. En Canadá se encuentra un índice similar al NFDRS, pero canadiense. Éste índice se llama “Sistema canadiense para la evaluación de incendios forestales” (*Canadian Forest Fire Danger Rating System – CFFDRS*), que comenzó a utilizarse en los años 70. Ver Figura 2.14.

Este sistema, está compuesto por 4 módulos (primera línea), donde la información meteorológica obtenida, el *Fire Weather Index* (FWI), se añade a los índices de ocurrencia, a la predicción del comportamiento del fuego (*Fire Behavior Prediction – FBP*) y a la humedad del combustible (Van Wagner,

1987). Así, se puede observar que el CFFDRS actúa de forma similar al NFDRS estadounidense, es decir, la parte operativa del sistema está basada en la meteorología, dejando de lado, al igual que el NFDRS, la vulnerabilidad.

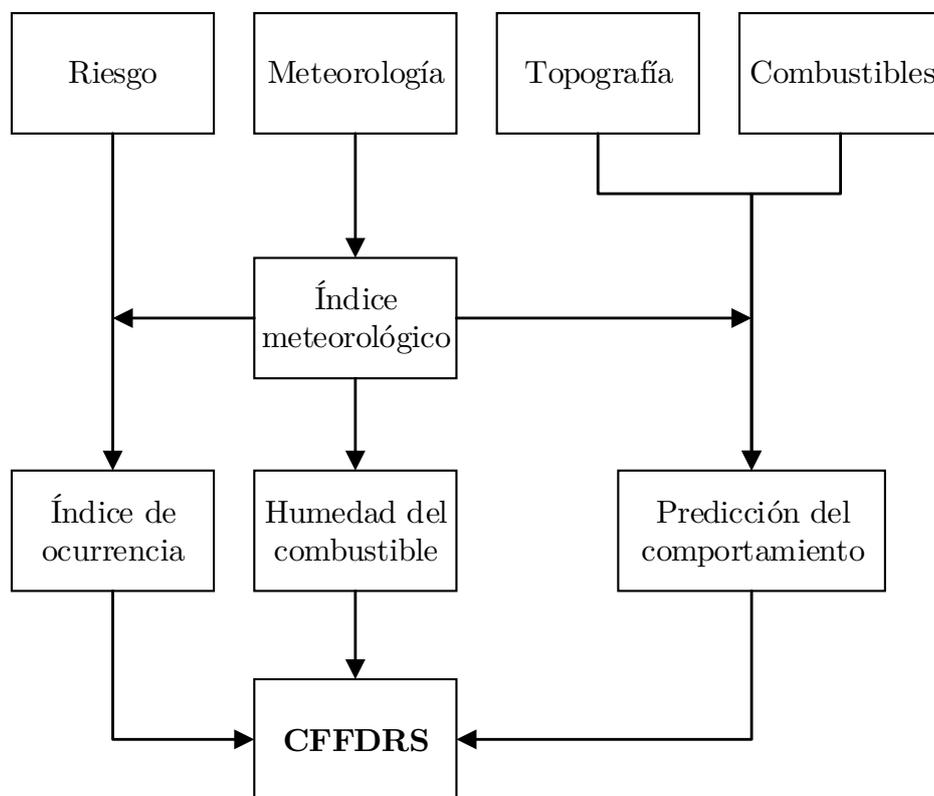


Figura 2.14: Esquema del índice CFFDRS canadiense.

Fuente: Salas y Cocero (2004).

2.1.2.3 Europa.

La Unión Europea (UE), debido al fuerte impacto de los incendios forestales en los países mediterráneos que la componen, formó en 1997 un grupo de investigación, el *Joint Research Centre (JRC)* para trabajar en el desarrollo y mejora de métodos para la evaluación y gestión del riesgo de incendios forestales a escala europea. En la página web de la JRC, se puede observar una subsección que se llama *European Forest Fire Information System (EFFIS)* (San Miguel Ayanz *et al.*, 2002), la cual está a cargo de proveer los servicios de protección ante incendios forestales en los países de la Unión Europea (JRC, 2015).

La gran diferencia de éste índice con el estadounidense y canadiense, es que éste es el primer índice que presenta la vulnerabilidad al daño como una variable relevante a considerar. Este índice de vulnerabilidad estima el daño probable que un incendio puede causar en un área concreta. Lo anterior es a partir de tres factores (Salas y Cocero, 2004):

- i. Erosión potencial obtenida a partir del tipo de suelo, pendiente y régimen de lluvias.
- ii. Nivel de protección de una determinada zona, por ejemplo: reserva nacional. (fragilidad e interés medioambiental).
- iii. Distancia a los asentamientos humanos, considera a las vidas humanas y las propiedades en peligro.

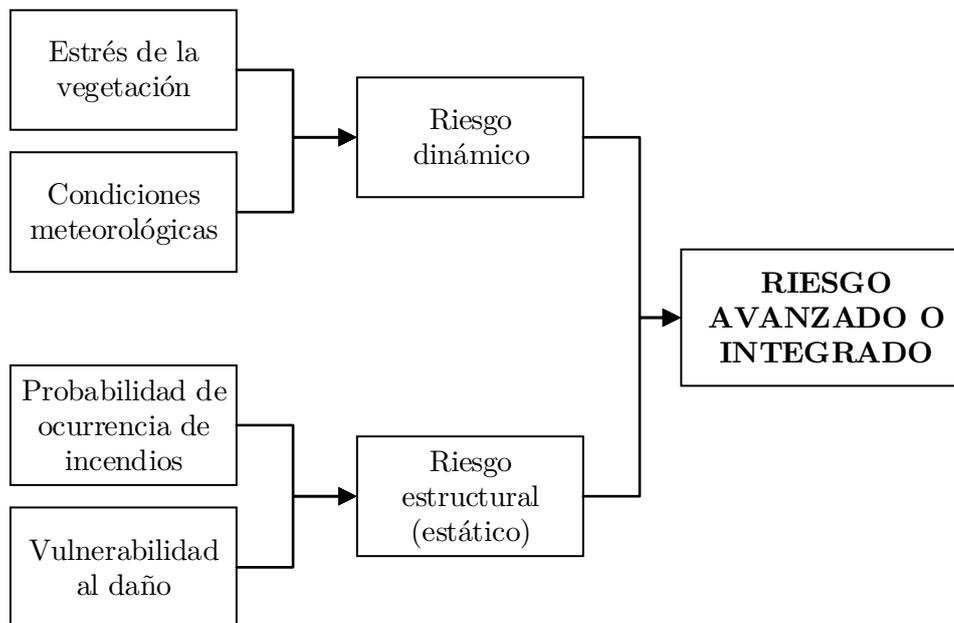


Figura 2.15: Esquema del Sistema de Peligro de Incendio Forestal por la JRC.

Fuente: Salas y Cocero (2004).

Un punto relevante a recalcar es que éste índice presenta, como parámetro de entrada, el estrés de la vegetación. Dicho estrés se basa en los índices de vegetación obtenidos a partir de las imágenes del satélite NOAA – AVHRR. El índice utilizado se llama el VSI (*Vegetation Stress Index* - Índice de estrés de la vegetación), que se basa en la pendiente acumulada del NDVI (*Normalized Difference Vegetation Index*) durante el verano (Illera *et al.*, 1996).

Otro punto significativo a recalcar, es que el índice europeo cuenta con un índice de riesgo que es considerado independiente de los índices estructurales y dinámicos comentados anteriormente. Este es el *Fire Potential Index* (FPI – Índice potencial de incendio), que ha sido adaptado al contexto europeo siguiendo la metodología original desarrollada por Burgan *et al.* (1998) en EE.UU, donde ha sido validada de manera satisfactoria (Salas y Cocero, 2004).

Como se pudo observar, los tres índices vistos tenían como variable el tipo de causalidad. Como se dijo con anterioridad, la gran mayoría de los incendios forestales son causados por el hombre. De hecho, Martínez *et al.* (2009) realizaron un estudio acabado para determinar un índice de incendios forestales producidos por el hombre para, así, introducirlo a la prevención del riesgo de éstos en España.

2.2. Teledetección Satelital

El tema en cuestión se enfoca en dos grandes estudios: La teledetección satelital, el análisis espectral y la elaboración de índices espectrales para estimar, a partir de ambas metodologías, el contenido de humedad de la vegetación como porcentaje de la misma (FMC). El foco de esta sección es poder dar a conocer cada uno de los dos estudios en torno a su teoría como a su aplicación. Así, a continuación se realizará un barrido bibliográfico de una serie de estudios que rondan el tema de fondo del presente proyecto. La finalidad es poder ir entendiendo y explicando cada uno de ellos de una forma deductiva y así establecer el conocimiento suficiente para sostener la hipótesis de que es factible explicar variables como el FMC a partir de información espectral y satelital. La [Figura 2.16](#) esquematiza los puntos a tratar en la presente sección.

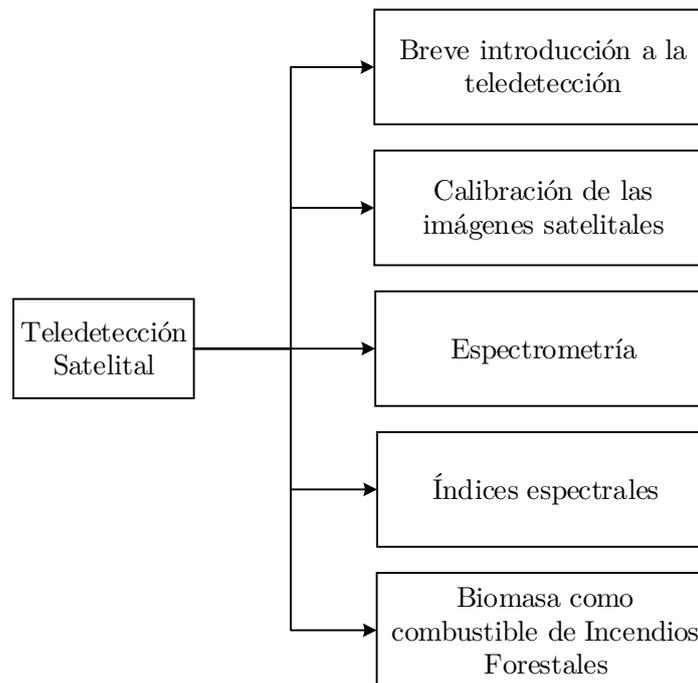


Figura 2.16: Esquema de los temas que se tratarán en esta sección.

Fuente: Elaboración propia.

2.2.1 Breve introducción a la Teledetección

[Chuvieco \(2010\)](#) define la teledetección como aquella técnica que permite obtener información a distancia de los objetos situados sobre la superficie terrestre. Para que esta observación remota sea posible, es necesario que exista algún tipo de interacción entre los objetos y el sensor. El sensor, que se denomina “carga útil” del satélite, es la herramienta de obtención de información del satélite y, de este enfoque, existen dos grupos: sensores pasivos y sensores activos. En la [Sección 2.2.1.2](#) se ahonda más sobre este tipo de especificaciones. A continuación se hablará sobre el espectro electromagnético, la física en que se sustenta la teledetección.

2.2.1.1 El espectro electromagnético.

Con la excepción de los objetos que se encuentran al 0 Kelvin, todos los cuerpos u objetos emiten radiación electromagnética. A su vez, los objetos también reflejan radiación que ha sido emitida por otros objetos. En tanto, el trabajo de la teledetección o de sensores de teledetección, es la interpretación de esta radiación. Es decir, el rol o función de los sensores es el entendimiento de la radiación

electromagnética emitida por los cuerpos y su interacción con las superficies y la atmósfera (Campbell y Wynne, 2011).

La energía electromagnética se genera por diversos mecanismos, incluyendo cambios en los niveles de energía de los electrones, aceleración de las cargas eléctricas, decaimiento radiactivo de sustancias y los movimientos térmicos de los átomos y moléculas (Campbell y Wynne, 2011). A modo de síntesis, la radiación electromagnética consiste en un campo eléctrico que varía, en términos de magnitud, en una dirección perpendicular a la dirección de propagación de la onda y, por otro lado, consiste en un campo magnético que se orienta perpendicularmente al campo eléctrico, en la misma dirección de propagación. Este tipo de ondas no necesita de un medio material para propagarse, su velocidad en el vacío es constante e igual a $c = 3 \cdot 10^8$ [m/s], la velocidad de la luz.

Todas las formas de energía electromagnética conocidas son agrupadas de acuerdo a su frecuencia, longitud de onda y energía, en el espectro electromagnético (ver Figura 2.17). Es importante destacar que aún no hay consenso en los valores fronterizos de cada región.

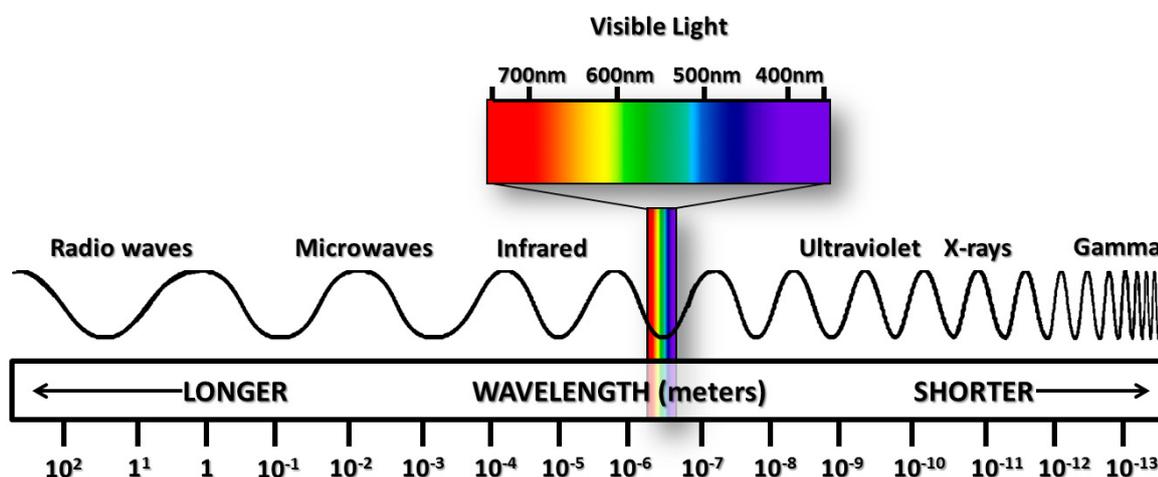


Figura 2.17: El espectro electromagnético en diversos rangos de longitudes de onda.

Fuente: Imagen obtenida de: CSI-NASA (2015).

Históricamente, las propiedades de la radiación electromagnética se han explicado por dos teorías aparentemente contrapuestas: aquella que la concibe como un haz ondulatorio (Huygens, Maxwell), y aquella que la considera como una sucesión de unidades discretas de energía, fotones o cuantos, con masa igual a cero (Planck, Einstein) (Chuvieco, 2010), en donde, de esta forma, la partícula viajará a la velocidad de la luz siguiendo la Teoría de la Relatividad de Einstein. Ahora bien, ambas teorías se pueden entrelazar, pues se ha demostrado que la luz presenta comportamientos que pueden explicarse de acuerdo a ambos postulados (Onda-Partícula). Así, se plantea la relación entre la teoría de partículas y la teoría óptica, donde se establece que la energía de un fotón está en relación con la longitud de onda, la velocidad de la luz y la constante de Planck.

Como resultado de la radiación electromagnética, se construye lo que se denomina el espectro electromagnético, el cual varía desde longitudes de onda (λ) cortas, que incluyen los rayos X y gamma, a longitudes de onda mayores, que incluyen las microondas y las ondas de radio (CCRM, 2014). Es así como este espectro se divide en diversas regiones, como se puede apreciar en la Figura 2.17.

2.2.1.2 Sensores y satélites de teledetección.

i. Tipos de sensores.

En cuanto al estudio de los tipos de sensores, cabe destacar que son —como se dijo con anterioridad— la carga útil que lleva el satélite, es decir, el instrumento abordo. Existen dos tipos de sensores, los sensores pasivos y los sensores activos. Los sensores pasivos son aquellos que funcionan por medio de la energía irradiada por el sol hacia los cuerpos en la superficie terrestre. Es decir, el satélite (sensor) capta la radiancia de los cuerpos gracias a que el sol provee a estos de energía. Este proceso se conoce como la reflexión, y es una de las formas más importantes en teledetección, ya que la gran mayoría de los satélites que orbitan el planeta se basan en dicho principio. Los sensores activos difieren con los sensores pasivos en que los primeros emiten su propia energía para captar la energía de respuesta de los cuerpos. Por ejemplo, en el caso de sensores activos LIDAR (*Light Detection and Ranging*), éstos miden la radiación devuelta ya sea por la superficie terrestre o por las partículas que componen la atmósfera cuando se ilumina por una fuente de rayos láser (Sobrino, 2000). Lo anterior se conoce como el proceso de reflexión-emisión (Chuvieco, 2010). Dentro de la clasificación de sensores activos se encuentran tres subgrupos, los cuales son: sensores fotográficos, óptico-electrónicos y de antena.

ii. Resolución de un sistema sensor.

Estes y Simonett (1975) definen la resolución de un sistema sensor como la capacidad u habilidad de éstos para discriminar información de detalle. Chuvieco (2010) agrega que la resolución de un sensor depende del efecto combinado de sus distintos componentes. Una mejora en el lente no supondrá necesariamente adquirir imágenes con mayor resolución si no se acompaña de una película de mayor sensibilidad, o no se modifican las condiciones de exposición, por ejemplo. En cuanto a los dos primeros términos abordados (*discriminar e información de detalle*), la forma de visualizarlo es la siguiente: es la diferencia entre determinar si un objeto está ahí (*detección*) o a una delimitación precisa de su contorno (*identificación*). Obviamente, la segunda requiere una resolución espacial mayor que la primera, se necesita “más detalle”. En cuanto a la *información de detalle* de la imagen, Campbell y Wynne (2011) dan a conocer la conveniencia de considerar que dicha información no solo se refiere al detalle espacial que proporciona el sensor, sino también al número y ancho de las bandas del espectro electromagnético que éste alberga. A continuación se realizará una breve referencia a los diversos tipos de resoluciones más utilizadas en la literatura.

a) Resolución Espacial.

La resolución espacial se refiere a la habilidad de distinguir pequeños objetos adyacentes en una imagen. A modo de síntesis: a mejor resolución espacial de un sistema, más fácil es detallar objetos en la imagen (Bakker *et al.*, 2009). En tanto, la unidad de medida de ésta resolución es en unidades de longitud. Se mide en milímetros sobre la foto —o metros sobre el terreno—, y depende de la longitud focal de la cámara y de su altura sobre la superficie. En cuanto a los sensores óptico-electrónicos, se utiliza más la definición del campo de visión instantáneo (IFOV – *Instantaneous Field of View*), el cual se define como la sección angular, medida en radianes, que observa el sensor en un momento determinado (Chuvieco, 1990). Pero, también se suele utilizar más el concepto de distancia sobre el terreno que corresponde a ese ángulo (d), que puede calcularse a partir de él, conociendo la distancia del suelo al sensor (h). Así, se tiene:

$$d = 2h \tan(\text{IFOV}/2) \quad (2.2)$$

Donde se asume que se trata de una observación vertical. La distancia del IFOV proyectado al suelo se corresponde con el tamaño de la mínima unidad de información incluida en la imagen, que se denomina píxel (*picture element* – Chuvieco, 2010). Existen, también, otros términos más complejos que el IFOV, como el ERE (*effective resolution element*) o EIFOV (*effective instantaneous field of view*).

La resolución espacial depende de varios factores, como lo son la altura a la que orbita el satélite, la velocidad de exploración y número de detectores (Chuvieco, 1990). También, existen otros tipos de factores más lógicos, como lo son la calidad del sistema óptico, los efectos de la dispersión atmosférica (que conducen a la pérdida de contraste y resolución), los movimientos de la imagen (el movimiento entre la cámara y el suelo causa distorsión y pérdida de resolución), entre otros (Bakker *et al.*, 2009).

La mayoría de las imágenes satelitales están compuestas por una matriz de elementos de la imagen (píxeles), que son la unidad más pequeña de la imagen. Por ejemplo, si un sensor tiene una resolución espacial de 20 [m] y una imagen de dicho sensor se expone a máxima resolución, cada píxel representará un área de 20 x 20 [m] en el suelo. En este caso, el tamaño del píxel y la resolución espacial son el mismo valor. No obstante, es posible exponer una imagen con un tamaño de píxel distinto a la resolución espacial del sensor que tomó dicha imagen. Una fotografía puede ser representada y expuesta en formato digital al subdividir la imagen en figuras con áreas de igual tamaño (píxel) y representa (cada píxel) el brillo de cada área con un valor numérico llamado “número digital” (Levin, 1999), del cual se hablará más adelante. Un ejemplo de resolución espacial se puede apreciar en la Figura 2.18.

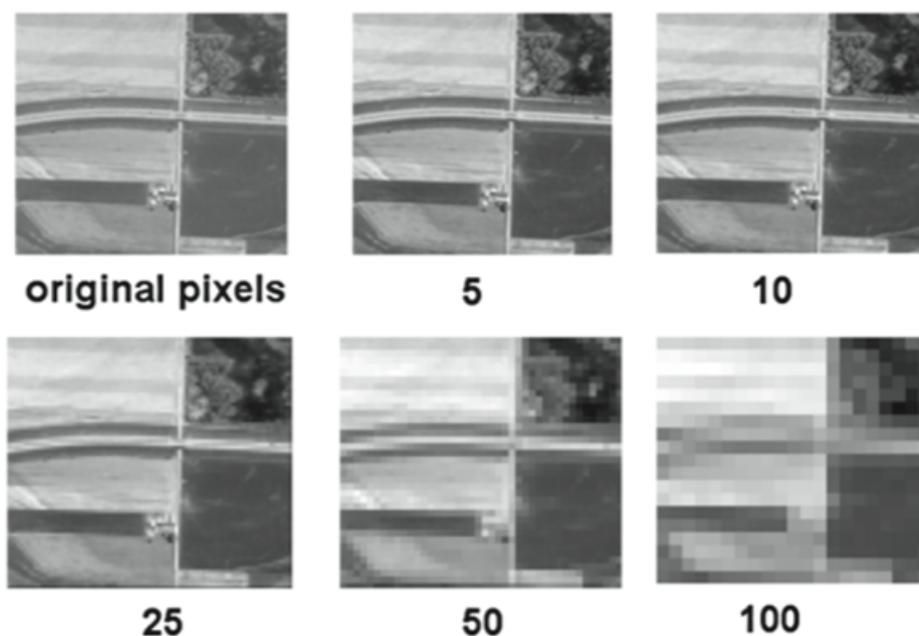


Figura 2.18: Resolución espacial. Un ejemplo en donde la resolución espacial ha sido degradada al promediar el brillo sobre bloques cada vez más grandes de píxeles

Fuente: Imagen obtenida de: Campbell y Wynne (2011) .

b) Resolución Espectral.

La resolución espectral indica el número y anchura de las bandas espectrales que puede discriminar el sensor. En este ámbito, un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral de las distintas cubiertas. Así, se podría establecer que a mayor resolución espectral, más información de detalle del espectro se tienen. Entre los sensores espaciales, la menor resolución espectral corresponde al radar y a los sistemas fotográficos. El radar trabaja normalmente en un solo canal mientras la fotografía puede ofrecer películas pancromáticas, infrarrojo, color natural o infrarrojo a color. Por otro lado, los sensores óptico-electrónicos ofrecen un mayor rango de bandas, desde las 3 de los primeros SPOT-HRV (verde, rojo e infrarrojo cercano) hasta las 220 ofrecidas por el sensor Hyperion, a bordo del satélite EO-1 de NASA (Beck, 2003; Chuvieco, 2010).

A modo de resumen, se tiene una clasificación de tres tipos de sensores en cuanto a resolución espectral se trata. Se tienen sensores pancromáticos, multiespectrales e híperespectrales. Donde el primero se encuentra, generalmente, entre los 400 – 850 nm (1 nanómetro = $10^{-9}m$) y no discrimina bandas (solo blanco y negro). El canal multiespectral considera bandas u regiones del espectro en donde se capturarán los datos (es el caso de la mayoría de los satélites de observación terrestre). En tanto, el canal híperespectral tiene bandas con separaciones muy finas, lo cuál le permite realizar análisis más detallados (CCRM, 2014), que vendría siendo, por ejemplo, el caso del sensor Hyperion del satélite *Earth Observation 1* (EO-1) de Nasa (Beck, 2003). Un ejemplo esquemático para entender la resolución espectral se puede apreciar en la Figura 2.19.

La mayor parte de los sensores requieren un mayor número de bandas para mejorar la discriminación de las cubiertas de interés, ya que a mayor resolución espectral, podrán reconocerse mejor los rasgos de absorción específicos de cada cubierta, o bien, donde se podrá analizar en mayor detalle la reflectividad y transmisividad de los objetos (Kruse *et al.*, 1993).

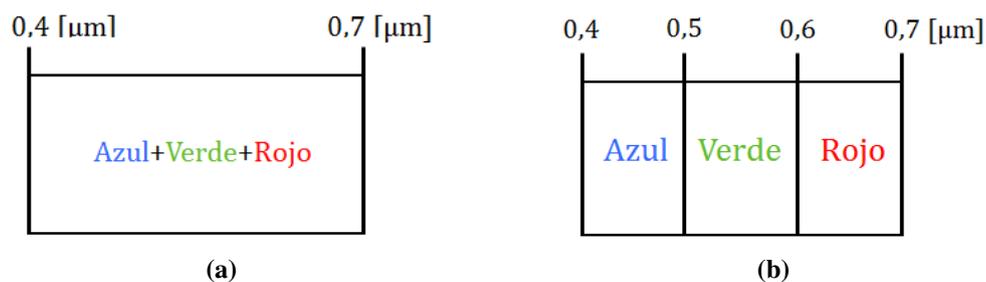


Figura 2.19: Diferencias entre (a) una sola banda que no discrimina colores (pancromática) y (b) una película a color que discrimina mayor número de bandas.

Fuente: Fundamentals of Remote Sensing (CCRM, 2014).

c) Resolución Radiométrica.

La resolución radiométrica hace mención a la sensibilidad del sensor en cuanto a su capacidad para detectar variaciones en la radiancia espectral que percibe (Chuvieco, 2010). Para los equipos digitales, la imagen se codifica en un formato binario, por lo que la resolución radiométrica suele identificarse con el rango posible de valores que almacena el sensor, medido como el número de bits que necesita cada valor numérico para almacenarse. Así, por ejemplo, el satélite Landsat 8 ofrece imágenes en 16 bits (USGS, 2015a), esto quiere decir que el sensor es capaz de captar un rango de 65.536 niveles de grises

(16 bits $\implies 2^{16} = 65.536$) por píxel. Y, sensores de satélites como, por ejemplo, el Landsat 1 con una resolución de 6 bits, por lo que discrimina 64 niveles de grises por píxel. Para apreciar las diferencias de mejor forma se puede observar la [Figura 2.20](#).

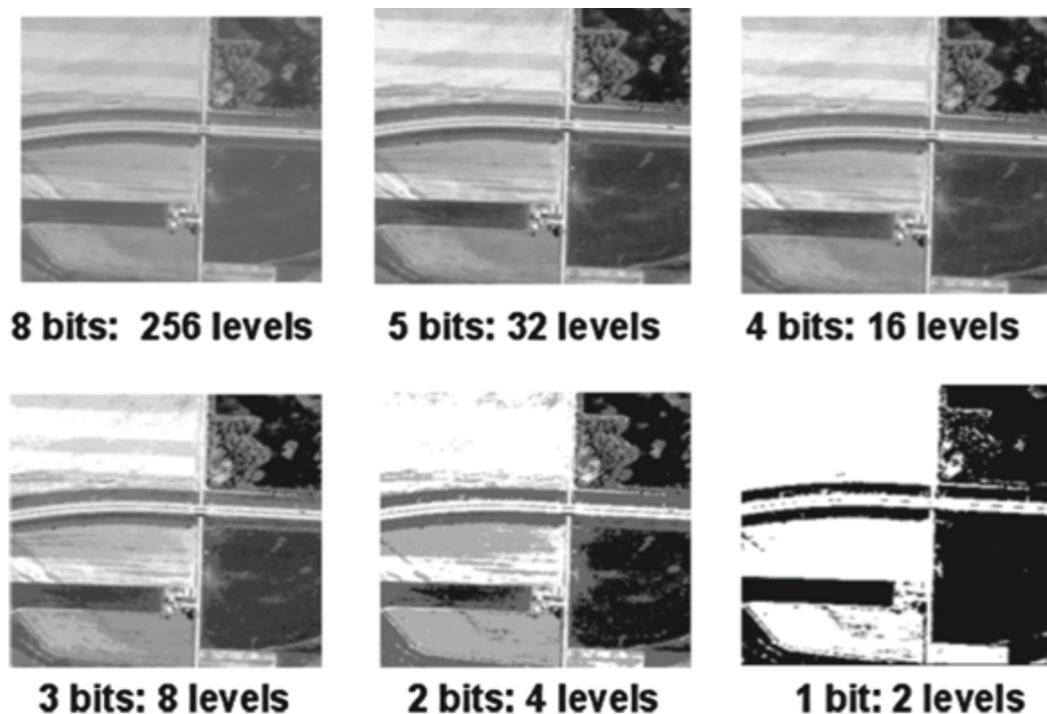


Figura 2.20: Resolución radiométrica. Ejemplo para diferenciar los niveles de grises.

Fuente: [Campbell y Wynne \(2011, p. 295\)](#).

d) Resolución Temporal.

Este concepto alude a la frecuencia de cobertura que proporciona el sensor, es decir, a la periodicidad con la que éste adquiere imágenes de la misma porción de la superficie terrestre. En función de lo anterior, hay ciertos factores que determinan dicha periodicidad, estos son – principalmente- : la altura, velocidad, inclinación, diseño del sensor, ángulo total de apertura (tamaño de la imagen) y condiciones atmosféricas (en caso de existir nubosidad no se podrá obtener información espectral de la imagen). Estas últimas, han sido cada vez más insignificantes, puesto que los sensores modernos incluyen la capacidad de observación no vertical (lo que se denomina sensores *enfocables*), facilitando la adquisición de datos sobre una zona de interés desde una órbita próxima ([Chuvieco, 2010](#)). Por ejemplo, el satélite Meteosat-9, entrega una nueva imagen de la misma área cada 15 minutos y así lo ha hecho a lo largo de muchos años, aunque – a su vez– una alta resolución temporal lleva de la mano un sacrificio: una baja resolución espacial (tamaño del píxel 3 x 3 km para las imágenes Meteosat-9, [Bakker et al., 2009](#)), ya que dicho satélite es de órbita geoestacionaria (se ubica a 36.787 km de altura, [EUMETSAT, 2015](#)), y como se vio anteriormente, la resolución espacial es inversamente proporcional a la altura orbital del sensor i.e a mayor altura orbital del sensor, menor es la resolución espacial.

e) Resolución Angular.

Se refiere a la capacidad de un sensor para observar la misma zona desde distintos ángulos ([Chuvieco, 2010](#); [Diner et al., 1999](#)). Éste término es bastante nuevo en contraste con los otros tipos de resolución que se vieron anteriormente. La finalidad es poder observar, de distintas posiciones, una cubierta o área determinada, ya que en la práctica hay algunas

superficies que presentan fuertes efectos de reflectividad bidireccional, entonces, para poder captar la mayor cantidad de reflectividad de los cuerpos, es necesario que el sensor pueda cambiar su dirección.

Hoy en día ya existen sensores que son capaces de proporcionar una observación multiangular. Tal es el caso de satélites como el NOAA–AVHRR (NOAA: *National Oceanic and Atmospheric Administration*; AVHRR: *Advanced Very High Resolution Radiometer*), que observan la superficie con distintos ángulos según la posición de la órbita del satélite (en el caso del AVHRR, el ciclo se repite cada 9 días) (Chuvieco, 2010). Sin embargo, se puede decir que esta última solución no es la más adecuada, ya que pueden existir severos cambios entre pasadas diarias del satélite. Así es como se han diseñado sensores que específicamente tienen la capacidad de observación simultánea en varios ángulos. Un ejemplo estaría siendo el ATSR–2, lanzado en 1995 a bordo del ERS-2, entre otros. Cabe destacar que el más sofisticados de este tipo de sensores a la fecha, es el MISR (*Multi-angle Imaging Spectroradiometer*), incluido en la plataforma (satélite) Terra (EOS AM-1), el cual es capaz de obtener nueve ángulos de observación, casi simultáneos, de la misma zona en diversas longitudes de onda (Chuvieco, 2010; JPL-CIT, 2015).

2.2.1.2.1 Tipos de satélites y sensores

En la actualidad existen más de 1.300 satélites en órbita (UCSUSA, 2015), entre ellos se encuentran satélites de observación terrestre, de navegación, científicos, militares, etc, que orbitan a distintas alturas. Estas órbitas se caracterizan, principalmente, en tres categorías (Aguirre, 2013), las órbitas bajas (LEO – *Low Earth Orbit*), las medias (MEO – *Mid-Altitude Earth Orbit*) y las órbitas geoestacionarias (GEO – *Geosynchronous and Geostationary Orbits*), ver Figura 2.21. Las LEO son aquellas que más interesan en el presente estudio, debido a que en éstas órbitas es donde se sitúan los satélites de observación terrestre, donde su altura típica varía entre los 500 y 900 km (Aguirre, 2013). Por ejemplo, el satélite Landsat 8 se encuentra en una órbita LEO a 705 km de altura (USGS, 2015a).

La finalidad de la presente sección es determinar las características de algunos sensores comerciales (de observación terrestre – en órbitas LEO) en base a la información que se dio a conocer anteriormente (tipos de resoluciones y bandas). El criterio que se utilizará para la selección de sensores es, simplemente, que serán los de libre acceso y los más utilizados por CIREN (*Centro de Información de Recursos Naturales*) en Chile. Dichas características se pueden apreciar en las tablas B.4, B.5, B.6 y B.7, ubicadas en el Anexo B.

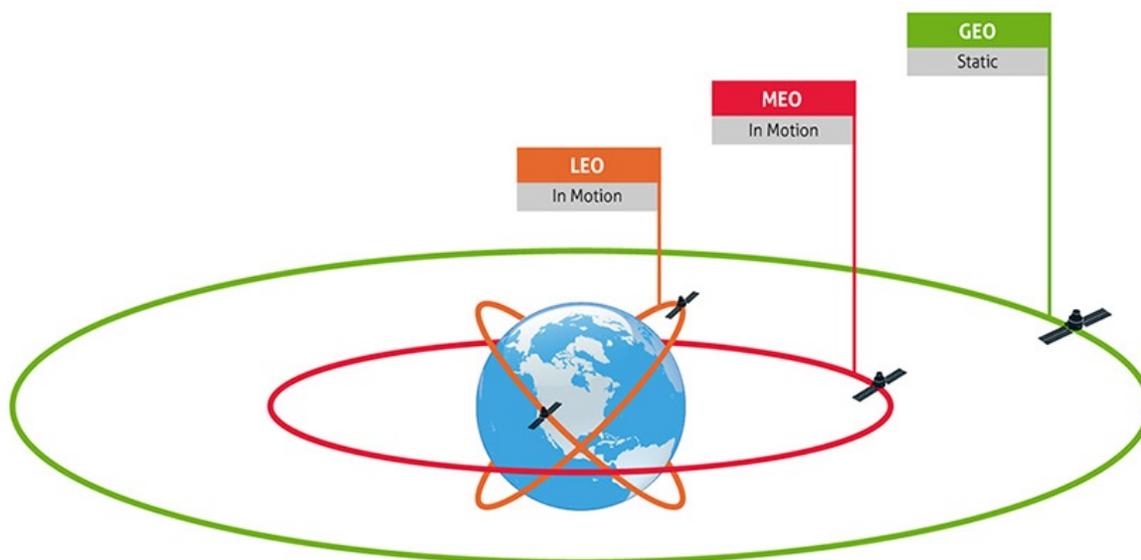


Figura 2.21: Órbitas principales de los satélites.

Fuente: Obtenida de: [Harriscaprock \(2014\)](#).

A modo de resumen, algunos términos abordados en las tablas B.4, B.5, B.6 y B.7 del Anexo B se pueden apreciar en la Tabla 2.1.

Tabla 2.1: Resumen de las características descritas en las tablas B.4, B.5, B.6 y B.7.

Concepto	Traducción	Explicación
Rango λ [μm]	Rango de longitud de onda	Corresponden a los rangos del espectro electromagnético que abarca determinada banda de un sensor.
R. Espacial [m]	Resolución Espacial	Es la unidad de medida del píxel, que se mide usualmente en metros. A mayor resolución espacial, se está hablando de un menor tamaño del píxel para una imagen, lo que implica mayor información si se compara con una imagen de un mismo sector a menor resolución espacial.
R. Temporal	Resolución Temporal	Hace referencia al tiempo que demora el satélite en pasar nuevamente por un mismo lugar.
R. Radiométrica [bit]	Resolución Radiométrica	Hace mención a la sensibilidad que posee el sensor para detectar variaciones en la radiancia espectral que recibe. A mayor resolución radiométrica (más “Bits”), mayor es el rango de valores que el sensor puede discriminar.
Swath	Ancho de barrido	Es el ancho de una imagen satelital, corresponde a una porción de la superficie de la tierra donde la información se recolecta.

Así, destacar que los únicos que son de libre acceso de las tablas anteriores, corresponden al satélite Landsat 8 (y toda su serie) y a los satélites Aqua & Terra, que poseen el sensor Modis. El resto pertenecen a distintas entidades, donde generalmente se separan en DigitalGlobe (EEUU) y Astrium (Europa). Cabe también destacar que el único sensor que posee varias bandas en el SWIR (*Short Wave Infrared*) es el sensor *SWIR* abordo del satélite WorldView 3.

2.2.2 Calibración de las imágenes satelitales

Las imágenes satelitales se componen de matrices de datos, cada dato o, dicho de otra forma, cada píxel en una imagen contiene lo que se llama un número o nivel digital (*Digital Number – DN – Chuvieco, 2010*). El nombre *número digital* se justifica por tratarse de un valor numérico, no analógico, pero que puede fácilmente traducirse a un intensidad visual o, si se prefiere, a un nivel de gris, mediante cualquier convertidor digital–analógico. Las correcciones de las imágenes tienen como misión el eliminar cualquier anomalía presente en éstas, ya sea en su localización o en la radiometría de los píxeles que la componen. Es decir, ya sea en situar ciertos puntos de la imagen en su ubicación geográfica correcta (georreferenciación), o reconstruyendo la radiancia detectada por el sensor a partir de los números digitales (DN) que vienen inicialmente con la imagen “cruda”. Los sensores satelitales miden la radiancia, lo que corresponde al brillo en determinada dirección hacia el sensor y se captura como DN. Es así como en la práctica las correcciones que se realizan se basan en tres puntos: la corrección geométrica, radiométrica y atmosférica (ésta última incluida en la corrección radiométrica). Existen otros tipos de correcciones (como la del ángulo de observación, *BRDF –Bidirectional Reflectance Distribution Function*, entre otras), pero las tres anteriores son las más básicas y necesarias (*Chuvieco, 2010*).

La principal razón de la calibración de las imágenes viene dado por la naturaleza de la teledetección. Primero, cualquier imagen adquirida por un sensor presenta una serie de alteraciones radiométricas y geométricas que, como ya se dijo, se deben a muy variados factores. Así, las imágenes pueden no coincidir exactamente con la radiancia–posición–forma–tamaño de los objetos incluidos en éstas (*Chuvieco, 2010*). Las distorsiones más comunes y frecuentes se pueden agrupar en los siguientes cuatro puntos (*Bernstein, 1976; Green et al., 2005; Mather, 1998*):

- **Distorsiones originadas por la plataforma.**

Se originan debido a las vibraciones que puede tener el satélite en su órbita. Dichas vibraciones pueden generar leves variaciones en la altitud de la órbita del mismo, efectos en la velocidad o bien en la orientación de cualquiera de sus tres ejes de acción (*roll –eje x–, pitch –eje y–, yaw –eje z, ver Figura 2.22*).

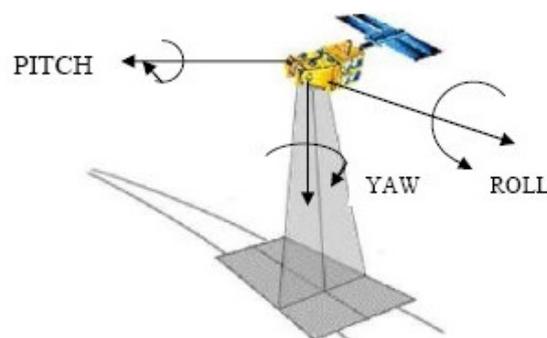


Figura 2.22: Ejes de acción de un satélite.
Fuente: Imagen obtenida de: [Teledec \(2016\)](#).

- **Distorsiones provocadas por la rotación terrestre.**

La mejor forma de explicarlo es mediante el siguiente ejemplo: El satélite Landsat 7 cuenta con un sensor multiespectral (MSS – ETM+) que es capaz de adquirir imágenes de un área de 185×185 km, en latitudes medias, en un tiempo de 28 segundos. En aquel lapso de tiempo, desde la primera hasta la última línea de barrido, la Tierra se desplaza sensiblemente (aprox. 8 km), lo que causa, junto a la propia inclinación de la órbita, una orientación de la imagen noreste–suroeste.

- **Distorsiones provocadas por el sensor.**

Estas distorsiones son asociadas a anomalías del sensor (por ejemplo en el sistema óptico, la no-linealidad del mecanismo de escaneo, entre otras) y puede generar factores de distorsión tanto geométricos como radiométricos.

- **Distorsiones provocadas por la atmósfera.**

Los distintos elementos que componen la atmósfera causan una modificación de la radiancia original proveniente de la superficie terrestre. Dentro de sus efectos, el más relevante es el de dispersión del flujo reflejado desde la superficie, a consecuencia de la presencia de aerosoles, gases y vapor de agua. Su efecto es un aumento de la señal recibida, traducéndose, para el usuario, información *falsa*.

2.2.2.1 Corrección geométrica

Las imágenes satelitales no son como mapas cartográficos en donde distancias entre puntos de la superficie del planeta, posiciones relativas de los puntos, las formas de áreas, entre otras, son representadas de forma precisa a determinada escala (Green *et al.*, 2005). De esta forma, el pre-procesamiento soluciona gran parte de estas distorsiones, pero generalmente es necesario un procesamiento más acabado denominado corrección geométrica para solucionarlas. Así, estas distorsiones pueden ser de varios tipos, pero principalmente se destacan: la distorsión panorámica – imagen en 2D captadas por el sensor versus las 3D de la Tierra–, la orientación del satélite, la rotación de la tierra, el error instrumental, la inestabilidad del satélite, entre otros (Green *et al.*, 2005).

Las imágenes se componen de píxeles cuyas posiciones son inicialmente referenciadas por sus números en la matriz de datos (filas y columnas). Para que la imagen sea útil en determinado lugar, es necesario ser capaz de relacionar dicha matriz de datos con posiciones a nivel del suelo o mar, siendo éstas en sistemas geodésicos como WGS84 (latitud y longitud) o UTM (*Universal Transverse Mercator*), que son posibles de obtener mediante sistemas de posicionamiento global (GPS) (Green *et al.*, 2005).

Así, la finalidad de la corrección geométrica es corregir, valga la redundancia, la geometría de la imagen asociada a las distorsiones mencionadas con anterioridad. Esta labor depende netamente de la imagen que uno utilice. Por ejemplo, una imagen del satélite Landsat 8 viene calibrada en términos de geometría, por lo que se asume como “lista” para trabajar con las siguientes correcciones que se le deben hacer a la imagen, pero las correcciones siguientes se asocian más a las necesidades del usuario. Sin embargo, existen una serie de imágenes que no vienen con esta corrección y en la práctica se utiliza un mapa con las coordenadas establecidas para ciertos puntos claves de la imagen. Luego, con algún programa especializado para el trabajo de imágenes satelitales, se le puede asignar algunos de estos puntos claves a la imagen con el fin de que el programa amplíe dichos puntos a una matriz de valores georreferenciados de la imagen a partir de algoritmos geodésicos.

2.2.2.2 Corrección radiométrica

Los sensores digitales almacenan la intensidad de la radiación electromagnética de cada punto observado de la superficie del planeta como números digitales (DN) para cada banda espectral de éste (Green *et al.*, 2005). Como se habló en la Sección 2.2.1.2 (*Sensores y satélites de teledetección*), el rango de los DN depende de la resolución radiométrica del sensor. Así, por ejemplo, el Landsat 8 puede adquirir valores de DN entre los 0 y 65.535, dado que su resolución radiométrica es de 16 Bits ($2^{16}=65.536$, pero se considera el comienzo desde el valor 0). La finalidad de la corrección radiométrica consiste, en simples palabras, en convertir los DN a unidades físicas de reflectancia. Para esto es necesario (Green *et al.*, 2005):

1. Convertir los valores de DN a radiancia espectral al nivel del sensor (con información del sensor).

2. Conversión de la radiancia espectral a reflectancia aparente (utilizando la intensidad de la iluminación solar).
3. Remover los efectos atmosféricos debido a la absorción y dispersión de la luz (corrección atmosférica).

El proceso asociado a la corrección radiométrica se puede apreciar en la [Figura 2.23](#). De esta forma, cabe destacar que la calibración no es única para todo sensor ni para mismas imágenes de determinado sensor. Depende de datos del fabricante, así como constantes de calibración, altura, ángulo de la adquisición de la imagen, entre otras. Hoy en día existen programas avanzados de procesamiento de imágenes satelitales (como ENVI, de la empresa Harris Geospatial Solutions) que van directamente al metadato de la imagen a obtener la información necesaria para la calibración. Los metadatos son un archivo de texto que viene incluido en una imagen satelital y que trae consigo información sobre la imagen como la hora de adquisición, fecha, formato, coordenadas de las esquinas, variables asociadas a las radiancia de las bandas, elevación solar, ángulo de azimut, distancia de la tierra al sol, entre otros. A su vez, es necesario abrir la imagen satelital a partir del metadato, debido a que éste contiene los vínculos para que el programa asocie cada imagen con determinada banda.

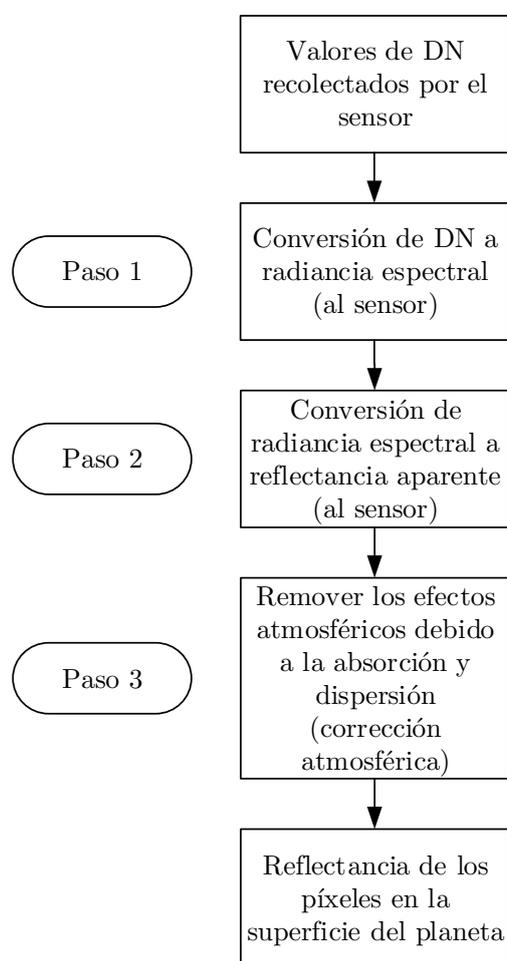


Figura 2.23: Proceso de la calibración radiométrica.

Fuente: Obtenido de [Green et al. \(2005\)](#), pág. 111.

A modo de ejemplo, en el [Anexo C](#) se presenta la metodología desarrollada por el fabricante ([USGS, 2015b](#)) para la calibración radiométrica del sensor OLI del satélite Landsat 8 (que comprende 9 bandas entre los 430 – 2.294 nm, como se puede apreciar en la [Tabla B.4](#) del [Anexo B](#)). De dicha calibración es posible determinar que el proceso es un tanto tedioso, y que una solución bastante

práctica es el uso de programas computacionales que tienen la facultad de leer y obtener información directamente del metadato de la imagen, donde se hace posible la automatización del proceso mediante algoritmos pre-establecidos.

El resultado obtenido en el proceso de la calibración de las imágenes provenientes del satélite Landsat 8 es la calibración radiométrica, es decir, se tienen los valores de la reflectancia al techo de la atmósfera (TOA – *Top of atmosphere*), valor que dista del buscado, que es el de la reflectancia planetaria a nivel de la superficie terrestre. Es entonces que aparece el concepto de la calibración atmosférica.

2.2.2.2.1 Corrección atmosférica

La influencia atmosférica no afecta por igual a los componentes del cálculo de la reflectividad: flujo descendente y ascendente, ya que el espesor que atraviesa la luz reflejada es distinto. En este caso hay que considerar, aparte de la irradiancia incidente (el flujo solar directo), la irradiancia difusa que se genera a partir de otros objetos vecinos. Así, la radiancia que capta el sensor no es la misma que aquella que emerge de la superficie terrestre. Es así como se busca determinar la reflectividad de la cubierta y «no» la influenciada por la atmósfera. En otras palabras, la misión de la corrección atmosférica es reparar los daños por los fenómenos atmosféricos, para que así la reflectancia calculada anteriormente en TOA, pase a ser determinada a nivel de la superficie terrestre.

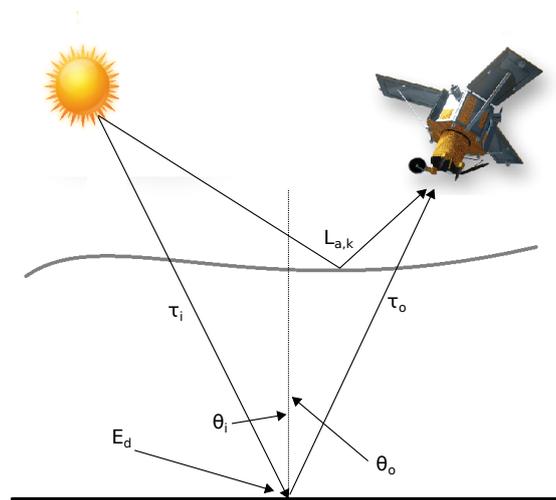


Figura 2.24: Efectos atmosféricos sobre el cálculo de la reflectividad.

Fuente: Elaboración propia a partir de [Chuvieco \(2010\)](#), pág. 274.

En la [Figura 2.24](#) se pueden apreciar las variables implicadas en la corrección atmosférica que influyen en la obtención de información real. De donde se puede establecer que:

$$L_{sen,k} = L_{suelo,k} \cdot \tau_{k,0} + L_{a,k} \quad (2.3)$$

Donde $L_{sen,k}$ es la radiancia espectral en la banda k recibida por un sensor satelital, $L_{a,k}$ es la radiancia aportada por la dispersión atmosférica en la banda k , la que recibe el nombre de “radiancia de trayectoria” (*Path Radiance*), $L_{suelo,k}$ es la contribución de la radiación que es difusamente reflejada por la superficie terrestre (que emerge), y $\tau_{k,0}$ es la transmitividad de la atmósfera en la dirección ascendente ([Gilabert et al., 1994](#)).

Ahora bien, respecto al flujo incidente, es necesario destacar que la irradiancia, que se define como la potencia incidente por unidad de superficie de la radiación electromagnética del sol (en este caso),

que llega al suelo ($E_{suelo,k}$) no es la que se mide en el techo de la atmósfera ($E_{0,k}$), sino que también es afectada por la atmósfera y por la componente de luz difusa (Chuvieco, 2010):

$$E_{suelo,k} = E_{0,k} \cdot \cos(\theta_i) \cdot \tau_{k,i} + E_{d,k} \quad (2.4)$$

Donde $\tau_{k,i}$ es la transmisividad atmosférica que afecta al rayo incidente, $E_{d,k}$ es la irradiancia difusa y θ_i es el ángulo cenital del flujo incidente.

Pero hay que destacar que la fórmula para determinar la reflectividad aparente (ρ_k^* ; que equivaldría a la presentada en la ecuación (C.3) presente en el Anexo C) que, de forma general, se puede calcular mediante (Chuvieco, 2010):

$$\rho_k^* = \frac{D\pi \cdot L_{sen,k}}{E_{0,k} \cdot \cos(\theta_i)} \quad (2.5)$$

En donde el resultado (ρ_k^*) es la reflectancia al techo de la atmósfera (TOA), pero al reemplazar el valor de la radiancia espectral recibida por el sensor ($L_{sen,k}$) por la radiancia que emerge de la superficie ($L_{suelo,k}$) y la irradiancia en el techo de la atmósfera ($E_{0,k}$) por la irradiancia que llega al suelo ($E_{suelo,k}$), entonces se tiene la reflectividad real (ρ_k), que considera los factores atmosféricos involucrados en el cálculo de ésta. Así, se tiene:

$$\rho_k = \frac{D\pi \cdot L_{suelo,k}}{E_{suelo,k}} \quad (2.6)$$

En donde D es el factor de corrección de la distancia tierra-sol (en función del día juliano). De esta forma, para resolver la reflectividad real de la cubierta en una determinada banda k de una imagen satelital, es preciso resolver la ecuación (2.6) y reemplazar las variables ($L_{suelo,k}$ y $E_{suelo,k}$) con las ecuaciones (2.3) y (2.4). De esta forma, la ecuación queda como (Chuvieco, 2010):

$$\rho_k = \frac{D\pi}{E_{0,k} \cdot \cos(\theta_i) \cdot \tau_{k,i} + E_{d,k}} \cdot \left(\frac{L_{sen,k} - L_{a,k}}{\tau_{k,0}} \right) \quad (2.7)$$

En efecto, para determinar la reflectividad real considerando los efectos atmosféricos es necesario calcular la transmisividad de la atmósfera (tanto descendente $-\tau_{k,i}$ como ascendente $-\tau_{k,0}$), la irradiancia difusa ($E_{d,k}$) y la radiancia atmosférica debido a la dispersión ($L_{a,k}$).

En consideración con lo anterior, es importante destacar lo laborioso de la calibración y la cantidad de variables involucradas. Así, al igual que para el cálculo de la reflectancia a nivel de TOA en base a las relaciones matemáticas, se torna un tanto tedioso. De hecho, el determinar, por ejemplo, los efectos atmosféricos a lo largo de una imagen Landsat 8 (que es una imagen de 190 km²) es bastante complejo sino imposible. Las variaciones de aerosoles o vapor de agua son imposibles de determinar para tal magnitud de imagen. Es así como nacen cuatro procedimientos que permiten generar una calibración atmosférica (King *et al.*, 1999; Sobrino, 2000): aquellos que se determinan a partir de mediciones *in situ* de, por ejemplo, la irradiancia o reflectividad del terreno; aquellos a partir de imágenes de otros sensores, donde algún sensor a bordo de una plataforma es capaz de medir el espesor atmosférico y beneficiar a otro sensor en la misma plataforma (caso del satélite Terra con los sensores MISR y Modis); a partir de modelos físicos de transferencia radiativa (pero que son bastante sujetos a los supuestos a utilizar) y, por último, a partir de datos de la propia imagen satelital, en donde Chuvieco (2010)

determina que resulta ser el método más operativo a la fecha, dado que no requiere información externa.

Lo ideal estaría siendo el corregir los fenómenos atmosféricos a partir de datos intrínsecos a la imagen capturada por un sensor, es así como se enfocará en detallar las alternativas inmersas en ésta teoría. Estas alternativas pueden ser de cuatro tipos (Chuvieco, 2010): (i) estimar la contribución de la atmósfera a partir de cubiertas que deberían presentar una reflectividad nula (métodos basados en el «objeto oscuro»); (ii) estimar el efecto atmosférico a partir de las diferencias de absorción y dispersión en distintas bandas del espectro para la misma imagen; (iii) realizar una homogeneización multitemporal entre imágenes y (iv) observar la misma zona con distintos ángulos. A continuación se enfatizará el primer punto.

La propuesta para corrección atmosférica basado en el objeto oscuro (*Dark object*) nace a partir del estudio realizado por Chavez (1975) para luego ser perfeccionado por el mismo autor en los años 1988 y 1996 (Chavez, 1988, 1996). El estudio de Chavez (1975) emerge con el supuesto de que las áreas cubiertas con materiales de fuerte absorción (aguas y zonas con sombras), deberían presentar una radiancia espectral muy próxima a 0. En la práctica, el histograma que se le realiza a una imagen en DN siempre presenta un mínimo superior a ese valor, que se atribuye al efecto de la dispersión atmosférica (Chuvieco, 2010). Así, una sencilla aproximación a la corrección atmosférica consiste en asumir que la radiancia atmosférica para una determinada banda k ($L_{a,k}$) corresponde al valor mínimo del histograma. Así, el método del *Dark object subtraction* resulta bastante sencillo y válido para estimar el espesor atmosférico de aerosoles, pero los errores pueden ser notables para valores de reflectividad altos (por sobre el 15 %), al no considerar las transmisividades del flujo incidente y reflejado.

Más tarde, Chavez (1988) sugiere estimar la transmisividad a partir del espesor atmosférico, que establece el hecho de no considerar la irradiancia difusa. Matemáticamente (a partir de la expresión (2.7)) quedaría:

$$\rho_k = \frac{D\pi \cdot (L_{sen,k} - L_{a,k})}{E_{0,k} \cdot \cos^2(\theta_i)} \quad (2.8)$$

De donde,

$$L_{a,k} = a_{0,k} + a_{1,k} \cdot DN_{MIN} \quad (2.9)$$

$a_{0,k}$ y $a_{1,k}$ corresponden a coeficientes de calibración para la banda k y ND_{MIN} corresponde al valor mínimo de número digital de la imagen que se puede obtener del histograma. No obstante, Chavez (1988) asumió que la transmisividad ascendente equivale a la unidad. Más tarde se estableció que dicho supuesto resultaba solo para algunos sensores, por ende, más adelante, Chavez (1996) establece una relación matemática con transmisividad estándar. Así, se tiene que:

$$\rho_k = \frac{D\pi \cdot (L_{sen,k} - L_{a,k})}{E_{0,k} \cdot \cos(\theta_i) \cdot \tau_{k,i}} \quad (2.10)$$

A partir de dicha relación es que nacen una serie de estudios determinando los valores de dicha transmisividad para diversas bandas, específicamente centradas en el estudio del sensor TM de la serie Landsat. Cabe destacar que éste procedimiento es el más básico de calibraciones atmosféricas, y es de hecho, la metodología que utilizan en CIREN para realizar la corrección atmosférica de las imágenes que procesan, en donde han obtenido resultados muy exitosos.

2.2.3 Espectrometría

La espectroscopía es el estudio de la interacción entre la radiación electromagnética y la materia, con absorción o emisión de energía radiante. Así, la espectrometría es la técnica espectroscópica para analizar el espectro de frecuencias característico de un movimiento ondulatorio (Crouch y Skoog, 2007). Para esto, se utilizan instrumentos como radiómetros o espectrómetros.

La radiación electromagnética interactúa con la materia cediéndole energía. Parte de dicha energía es absorbida, otra es reflejada y la diferencia es transmitida. Así, el flujo incidente (φ_i) puede descomponerse en los siguientes términos (Chuvieco, 2010):

$$\varphi_i = \varphi_r + \varphi_a + \varphi_t \quad (2.11)$$

En donde φ_r , φ_a y φ_t corresponden al flujo reflejado, absorbido y transmitido, respectivamente. Al expresar la ecuación (2.11) en unidades relativas (dividiendo por φ_i), se tiene que:

$$1 = \rho_\lambda + \alpha_\lambda + \tau_\lambda \quad (2.12)$$

Donde ρ_λ , α_λ y τ_λ corresponden a la reflectancia, absorción y transmisividad a determinada longitud de onda (λ) en donde la suma de estas es equivalente a la unidad. La proporción del flujo incidente que es reflejado, absorbido y transmitido depende de las características de la superficie y de la longitud de onda a la que sea observado (Chuvieco, 2010). En la Figura 2.25 se expresa la interacción del flujo solar incidente y su descomposición.

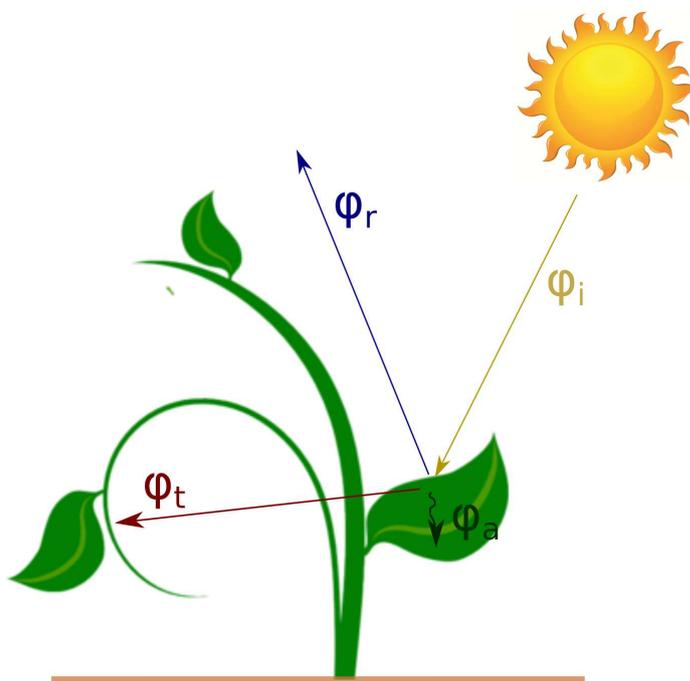


Figura 2.25: Descomposición del flujo solar incidente.

Fuente: Elaboración propia.

Un radiómetro es un instrumento que permite cuantificar los valores de absorbitancia, reflectancia y transmisividad de un objeto a determinada longitud de onda (λ). Los radiómetros pueden ser de dos tipos, espectro-radiómetros (o espectrómetros), con sensores que miden espectros continuos, y

radiómetros (o radiómetros de filtro), cuyos sensores miden un número predeterminado de bandas. La diferencia radica en que la energía que llega a los espectrómetros es a través de un prisma o rejilla difractiva. Así, variándose la posición del prisma o la apertura de la rejilla se consigue un espectro continuo. Los radiómetros poseen filtros que permiten el paso de la energía de una determinada longitud de onda, con lo que el número de bandas espectrales que diferencia el sensor están en función del número de filtros (Vaughan, 2001).

La luz que entra a un espectrómetro (o espectro-radiómetro) pasa por una serie de procesos para obtener el espectro de lo que se observa, a continuación se explicará el recorrido que ésta realiza a partir del funcionamiento de dichos instrumentos ópticos (BWTEK, 2016; OceanOptics, 2016a):

- La luz entra a través de la fibra óptica hacia la entrada del espectrómetro.
- La luz divergente es colimada por un espejo cóncavo y dirigida hacia una rejilla de difracción.
- La rejilla difracta la luz colimada y conduce dicha luz difractada hacia el espejo de enfoque.
- El espejo de enfoque recibe la luz reflejada de la rejilla y enfoca la luz hacia un lente detector.
- El lente detector recibe la luz enfocada del espejo y se forma la imagen sobre este. Los fotones de luz se convierten en electrones, los que son digitalizados y conducidos hacia un computador, que a partir de algún programa especializado lee y traduce la información espectral.

Las limitaciones del uso de espectrómetros varía según el tipo de análisis que se desee realizar, así como también por el tipo de instrumento que se está utilizando. Generalmente, los análisis espectrales por medio de espectrómetros se realizan en laboratorios, con fuentes de iluminación artificial (lámparas de halógeno, tungsteno, xenon, etc). Por otro lado, los radiómetros son más utilizados para realizar mediciones en el campo *in situ*. Es importante destacar que estos instrumentos requieren, la mayoría, una calibración previa para determinar los blancos y el fondo (Vaughan, 2001). Así, habitualmente se procede a calibrar el blanco con difusores ópticos, que consisten en materiales lambertianos (la radiación es reflejada en todos los ángulos en igual forma) que se distinguen por sus acabados color blanco mate. Un ejemplo es el caso de la WS-1 que ofrece la empresa OceanOptics (OceanOptics, 2016e). En el caso del fondo o *background*, se recomienda tapar con un paño completamente negro el lente del instrumento, o bien de la fibra óptica conectada al lente del instrumento AGSENS (2015).

Los espectrómetros también se han utilizado para estudiar el comportamiento espectral de la vegetación *in situ* (Vaughan, 2001). En donde es importante destacar que la mayoría de éstos espectrómetros realizan las mediciones por medio de fibras ópticas que se unen al lente del instrumento. Por ende, existen diversos factores físicos que influyen en la medición del espectro de reflexión (reflectancia). Cualquier superficie modifica el campo radiativo de tal manera que la interacción de la radiación global procedente del sol con la superficie, tanto directa como difusa, determina una radiación ascendente, reflectada y otra radiación difundida, así como una radiación absorbida por la cubierta (Vaughan, 2001). Un claro ejemplo es la fuente de irradiancia primaria: el Sol. Sin embargo, cabe destacar que la mayor parte de estos efectos tienen lugar en longitudes de onda superiores a los 3.000 nm. Entre los efectos se encuentran, de los más relevantes, el ángulo de elevación solar, los efectos atmosféricos y de aerosoles, y los tipos de radiación solar que percibe el objeto, ya sea directa, indirecta o difusa (Vaughan, 2001). En la radiometría de campo hay que considerar los factores atmosféricos, ya que se trata de condiciones sumamente cambiantes en acotados espacios de tiempo, especialmente para el vapor de agua, por lo que Vaughan (2001) recomienda minimizar el tiempo transcurrido entre la medición de referencia (el blanco y el fondo – *background*) y la del objetivo (muestra), ya que en cuestión de segundos pueden existir variaciones de hasta 5 % de la radiación solar media en días aparentemente despejados.

En la literatura se ha encontrado que la medida de analizar espectralmente la vegetación es por medio de la reflectancia. Es decir, en resultados de reflectancia como porcentaje (%) a una determinada

longitud de onda. La relación entre la radiación incidente (luz solar) y la radiación reflejada (por el objeto bajo análisis) constituye lo que se denomina reflectividad (Vaughan, 2001), que considera valores desde 0 (el fondo negro, absorción total) a 1 (el blanco, máxima reflectividad). Entender el concepto anterior es clave, ya que luego de una calibración es importante verificar que para dichos valores, por ejemplo, el blanco se debe situar en una línea horizontal en el 100 % a lo largo del espectro captado por el instrumento. Así como el negro (o la completa absorción) se debe encontrar a lo largo del espectro en un 0 % de reflectividad. Es así como se construye una curva característica de la vegetación, de la cual se pueden obtener índices que pueden explicar diversos estados de la misma (Chuvieco, 2010) (ver Sección 2.2.4 para más información). Estas curvas reciben el nombre de “firmas espectrales”, y son características de un determinado tipo de vegetación (Chuvieco, 2010). Un ejemplo de un espectro de reflexión continuo entre los 400 y los 2.500 nm de vegetación viva (de la especie *pinus radiata*) se puede apreciar en la Figura 2.26.

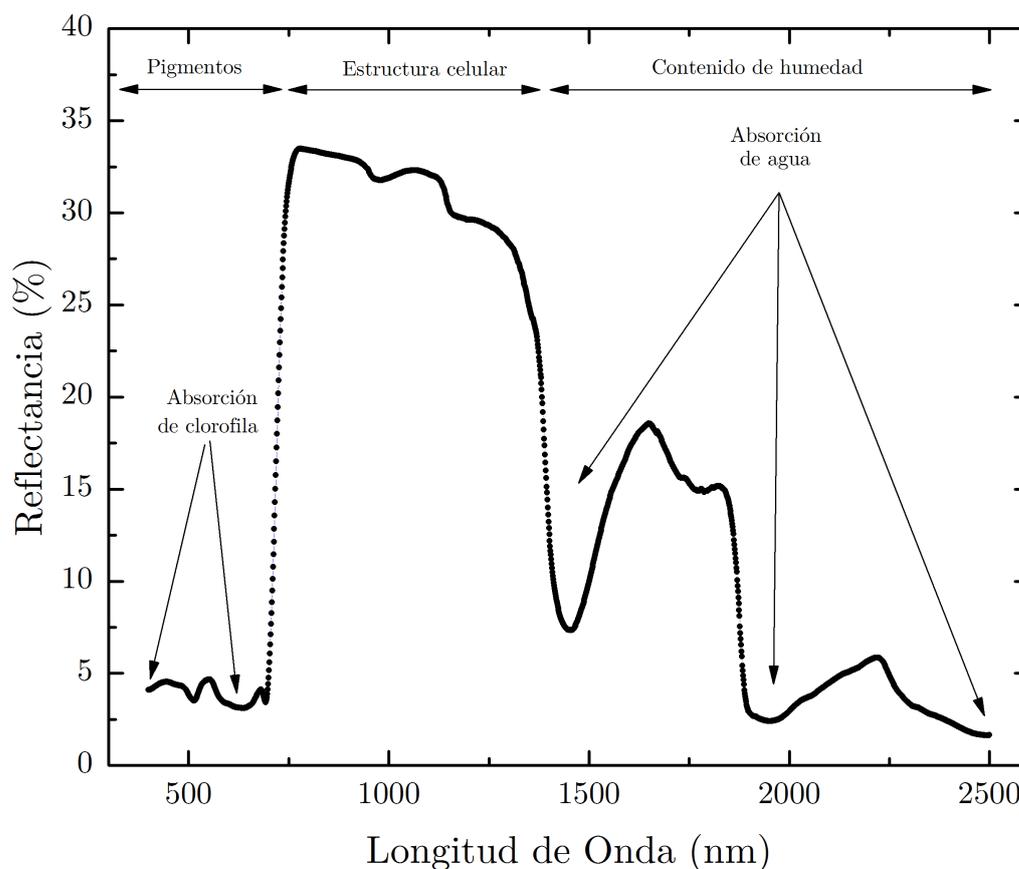


Figura 2.26: Reflectancia de vegetación viva de la especie *Pinus Radiata*.

Fuente: Elaboración propia a partir de simulación con PROSPECT.

2.2.3.1 Regiones del espectro

Para comprender la forma en que se distribuye la energía en el espectro electromagnético, resulta necesario realizar una clasificación de las regiones del espectro en base a los procesos que ocurren a nivel de la vegetación en las diversas longitudes de onda, es decir, analizar el efecto que ejercen sobre la reflectancia las propiedades físicas y químicas de la vegetación (Jacquemoud y Baret, 1990). A continuación se presentará en breve algunas características de algunas regiones del espectro electromagnético, restringiéndose al rango comprendido entre los 400 y 14.000 nm.

- En el caso de las longitudes de onda entre los 400 a 700 nm se encuentra el denominado espectro visible (VIS), en el cual se localiza toda longitud de onda que el ojo humano es capaz de captar,

todo lo que se puede ver (Chuvieco, 2010).

- o Entre los 700 a 1.200 nm se encuentra el infrarrojo cercano (*Near infrared* – NIR), que tiene una especial capacidad para discriminar masas vegetales y concentraciones de humedad (Chuvieco, 2010; Peñuelas *et al.*, 1993, 1997).
- o Luego, entre los 1.200 y 8.000 nm se encuentra el infrarrojo medio, el cual, a su vez, se divide en dos secciones. En el primer tramo se encuentra el infrarrojo de onda corta (*Short-Wave Infrared* – SWIR) que se sitúa entre los 1.200 y 2.500 nm y resulta ser una región idónea para estimar el contenido de humedad en la vegetación o los suelos (Ceccato *et al.*, 2002a,b; Chuvieco, 2010; Gao, 1996; Hardisky *et al.*, 1983; Jackson *et al.*, 2004).
La segunda banda dentro del infrarrojo medio está comprendida entre los 2.500 a 8.000 nm, y suele denominarse más propiamente tal como infrarrojo medio (*Middle Infrared* – MIR), siendo determinante para la detección de focos de alta temperatura (incendios o volcanes activos), y estimaciones de algunos gases atmosféricos (Chuvieco, 2010).
- o En cuanto a la región comprendida entre los 8.000 a 14.000 nm se encuentra el Infrarrojo lejano o térmico, que incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres (Chuvieco, 2010).
- o Cuando se habla de longitudes de onda por encima de 1 mm, entonces se refiere a las microondas, que son ondas de gran interés por ser un tipo de energía bastante transparente a la cubierta nubosa (Chuvieco, 2010).

De esta forma, es importante destacar que la región en la que se basan la mayoría de los satélites de observación terrestre de tipo pasivo se sitúan en el espectro visible (VIS), el infrarrojo cercano (NIR) y el infrarrojo de onda corta (SWIR). Así como también la mayoría de los radiómetros o instrumentos híperspectrales.

El entender las razones de dicho comportamiento de reflectancia de la vegetación en el dominio óptico resulta fundamental para comprender, como se dijo anteriormente, el efecto que ejercen sobre éste las propiedades físicas y químicas de las hojas. Existe la influencia de un parámetro denominado “estructura interna” de la hoja, el cual se hace presente a lo largo de toda la región comprendida entre los 400 y 2.500 nm, que se torna aún más importante en la zona del infrarrojo cercano (NIR) (en un 70–80 %), lugar donde la absorción disminuye considerablemente (y por ende la reflectancia aumenta, ver la Figura 2.26 para entender gráficamente). El efecto del parámetro de estructura interna es complementado por la influencia del contenido de materia seca (*Dry Matter Content*), principalmente por lignina, celulosa y otros hidratos de carbono estructurales de la vegetación (Ceccato *et al.*, 2002b; Jacquemoud *et al.*, 1996).

La absorción en la región visible es controlada por el contenido de pigmentos fotosintéticos, especialmente por la clorofila (Ceccato *et al.*, 2002b). Los fotones absorbidos en el proceso son utilizados por los electrones libres para realizar transiciones electrónicas y, de esta forma, abastecer de energía a los centros de reacción (Young *et al.*, 2009).

Por último, la absorción en el SWIR es ocasionada, principalmente, por el contenido de agua en la vegetación, seguidas por la influencia que ejerce el contenido de materia seca sobre la reflectancia en dicha región (Ceccato *et al.*, 2002a,b; Gao, 1996; Jackson *et al.*, 2004). Lo anterior se puede observar en los esquemas realizados en la Figura 2.26. Es importante notar que las principales longitudes de onda para la absorción de agua se concentran al rededor de los 1.450, 1.940 y 2.500 nm (Carter, 1991).

2.2.3.2 Trabajo de campo espectral

El trabajo de campo se ha implementado con el fin de analizar las variables que afectan a un estudio en particular o bien a un objeto determinado. En el ámbito de la vegetación y la información satelital, el trabajo de campo se define como aquel para poder validar los resultados obtenidos de una imagen satelital, en materia de estados tanto físicos como biológicos de la vegetación, con información obtenida en terreno a partir de instrumentos ópticos tales como radiómetros o espectrómetros, como se dijo al comienzo de la [Sección 2.2.3](#) (Vaughan, 2001).

En general, cuando se procede a analizar el espectro de la vegetación en el espectro óptico (entre los 400 – 2.500 nm), éste suele realizarse en un laboratorio con espectrómetros que utilizan fuentes de luz como, por ejemplo, luces halógenas para la región ultravioleta, visible e infrarrojo cercano, luces de xenón para aplicaciones más relacionadas con la reflectancia, luces de tungsteno para aplicaciones entre el rango visible e infrarrojo, entre otras (OceanOptics, 2016b). Pero el trabajo de campo en ésta materia tiene un enfoque de analizar la vegetación en su estado natural o, dicho de otra forma, de analizar el espectro con la fuente de luz natural: el sol (Vaughan, 2001). La idea de esta metodología va con el fin de poder establecer un patrón de relación con la información espectral obtenida a partir de imágenes aéreas o sensores remotos, pero claramente nacen una serie de perturbaciones en las mediciones que no se pueden dejar de lado. Entre dichas perturbaciones “naturales” se encuentran la cantidad de luz, el viento, la temperatura, la nubosidad, etc, que claramente no existen bajo condiciones experimentales en ensayos de laboratorio (Vaughan, 2001).

Pero si bien contienen una serie de factores “naturales” asociados a la obtención del espectro, son factores que también se observan en las imágenes satelitales. El principal beneficio tras el trabajo de campo es la obtención de datos con una mayor exactitud, aunque existen problemas para asegurar la significancia espacial y temporal, dado la especificidad del muestreo y los costos asociados (Aguado *et al.*, 2004).

2.2.3.3 Modelos de transferencia radiativa

Existen bastantes factores que determinan la reflectancia de una cubierta vegetal: el flujo solar incidente, las propiedades espectrales de los elementos que componen la cobertura vegetal, la arquitectura de la cubierta y la reflectancia del suelo (Goel, 1988). La estructura de la cubierta vegetal es compleja, en donde sus elementos se distribuyen de forma engorrosa, por lo que determinar el modo en el que la radiación interacciona con ella requiere de diversas simplificaciones (Berjón, 2007). Un modelo de transferencia radiativa, en este caso aplicado a la vegetación, consiste en la simulación de información espectral (reflectancia) a partir de parámetros físicos y químicos. A continuación se presentarán dos casos: los modelos de transferencia radiativa a nivel de hojas y a nivel del dosel.

1. Nivel de hoja.

De los elementos estructurales de la vegetación, las hojas son en general los que mayor influencia tienen sobre la firma espectral de la vegetación. Lo anterior es debido, principalmente, a que son los elementos de la vegetación con una mayor superficie expuesta, y dado que normalmente la observación de la vegetación en el campo de la teledetección se realiza en ángulos cercanos a la vertical, otros elementos como los tallos van a tener una importancia bastante menor (Berjón, 2007). En la hoja, la reflectancia total se compone de dos términos. El primero de ellos considera la fracción de luz que es reflejada directamente por la superficie de la hoja (especular) y el segundo, aquella que es reflejada indirectamente por los tejidos de la hoja (difusa) (Jacquemoud y Ustin, 2008) (ver la [Figura 2.27](#)). Los modelos de transferencia radiativa sólo consideran el término difuso, puesto que suponer que la hoja actúa como un espejo dista bastante de la realidad (Jacquemoud y Ustin, 2008).

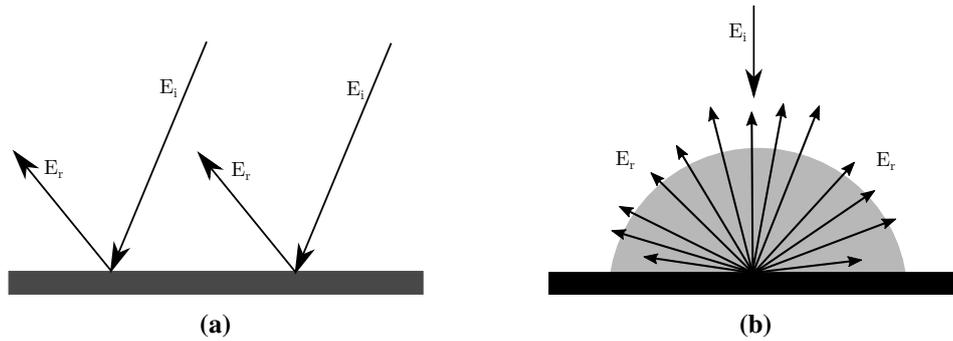


Figura 2.27: Tipos de reflectancia. (a) Especular (tipo espejo) y (b) Difusa (en todas las direcciones).

Fuente: Elaboración propia a partir de Máximo y Alvarenga (2008).

La interacción de la radiación electromagnética con las hojas de las plantas depende de sus propiedades químicas y físicas. La epidermis es el primer tejido que encuentra la luz, y por lo tanto ésta juega un importante papel en la reflectancia bidireccional de la hoja (Govaerts *et al.*, 1996). Por otro lado, la absorción de la radiación en las hojas se debe principalmente a la presencia de pigmentos fotosintéticos en los cloroplastos (clorofila a, clorofila b, carotenoides, etc.) y el agua, como se dijo anteriormente. En tanto, es importante que los modelos de transferencia radiativa tengan en cuenta la estructura interna de las hojas. El mesófilo esponjoso se caracteriza por la abundancia de espacios intercelulares, llenos de aire, que facilitan el intercambio gaseoso entre la planta y la atmósfera. En consecuencia, la luz que viaje a través de la estructura celular se encontrará con varios cambios de índice de refracción (Berjón, 2007) (ver la Figura 2.28).

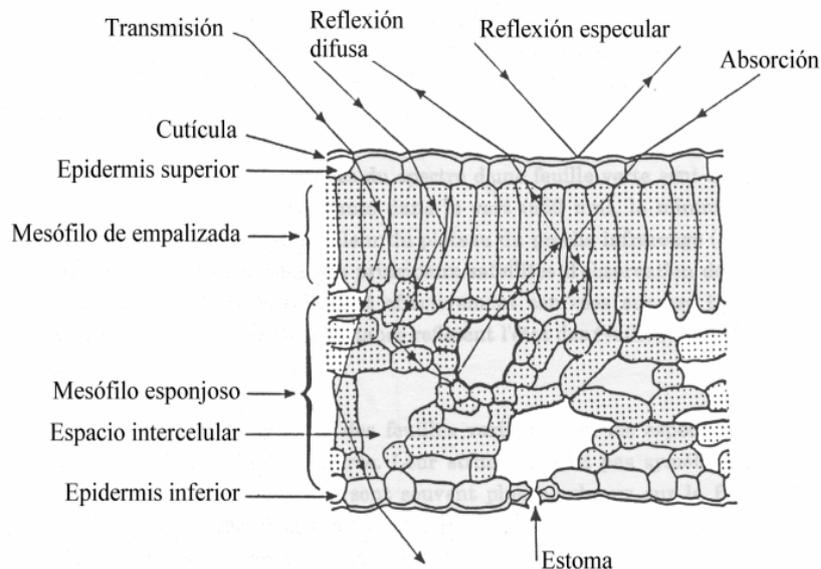


Figura 2.28: Estructura interna de la vegetación.

Fuente: Obtenida de Berjón (2007, p. 21).

La baja reflectividad en la porción del espectro visible de la vegetación (<10 %) se debe al efecto absorbente de los pigmentos de la hoja, principalmente las clorofilas, xantófilas y carotenos (Chuvieco, 2010). De hecho, es posible observar valores “mínimos” de absorción (donde la reflectancia disminuye) en torno a los 440–450 nm y 645–670 nm (Berjón, 2007; Chuvieco, 2010), como se señala en la Figura 2.26. De hecho, al situarse en los, aproximadamente, 550 nm se puede dar cuenta de un *peak* de reflectancia, que coincide con la banda verde del espectro visible, y causa el color con la que el ojo perciben la vegetación vigorosa (Chuvieco, 2010).

Por otro lado, la elevada reflectividad en el infrarrojo cercano (NIR) se debe, por un lado, a la baja absorción de las clorofilas y, por otro, a la estructura celular interna de la hoja (Chuvieco, 2010). La vegetación se compone, en esencia, por cuatro capas: la epidermis superior e inferior, el mesófilo de empalizada y el mesófilo esponjoso. Tanto la epidermis superior como inferior juegan un rol importante en la regulación térmica de la planta y en su absorción de dióxido de carbono (CO₂). El mesófilo de empalizada alberga los cloroplastos, y en el mesófilo esponjoso, como se dijo anteriormente, se generan intercambios gaseosos necesarios para la respiración de la planta. Debido a ello, dicha porción cuenta con cavidades de aire internas que dispersan la mayor parte de la radiación incidente en el infrarrojo cercano (NIR) (Gates *et al.*, 1965; Horler *et al.*, 1983). Así, una hoja sana ofrece una alta reflectividad en esta banda (Chuvieco, 2010).

En el infrarrojo de onda corta (SWIR), los niveles de reflectancia y transmitancia son esencialmente determinados por el contenido de agua de la hoja (Ceccato *et al.*, 2002b; Chuvieco, 2010; Gao, 1996). De esta forma, se puede caracterizar una vegetación sana como aquella que presenta una baja reflectividad en el SWIR (Chuvieco, 2010).

Una vez que se entienda lo que representa cada región del espectro óptico en materia de la vegetación, es entonces que se puede adentrar un poco más en el modelo de transferencia radiativa como tal. Como se podrá haber notado, es bastante complejo modelar lo que existe detrás de la estructura interna de una hoja, pero se han diseñado modelos que mediante el uso de supuestos han simplificado la realidad y han brindado resultados aceptables y cercanos a la realidad (Jacquemoud y Baret, 1990). El modelo más utilizado, dado su baja complejidad, es el *Generalized Plate Model* creado por Allen *et al.* (1970), un modelo que incorpora el supuesto de que las hojas están formadas por “N” capas homogéneas que se separan por “N-1” espacios de aire, que soluciona el problema de su antecesor, el *Plate Model* (Allen *et al.*, 1969), que consideraba las hojas como una superficie compacta, hecho que dista de la realidad.

Ahora bien, la particularidad del modelo de Allen *et al.* (1970) funciona para hojas planas, mas no del todo bien para hojas en forma de “agujas”. En dicho caso se recomienda utilizar modelos del tipo *Compact Spherical Particle Models* (Dawson *et al.*, 1998; Jacquemoud y Ustin, 2008), siempre y cuando se tenga conocimiento del diámetro medio de la célula y el espacio de aire intercelular (Moorthy *et al.*, 2004), variables un tanto complejas de obtener.

La finalidad de un modelo de transferencia radiativa es, entonces, simular un espectro continuo u bien las propiedades ópticas de las hojas a determinadas longitudes de onda. Los modelos *Generalized Plate Model* y el *Compact Spherical Particle Models* son los modelos tras PROSPECT (Jacquemoud y Baret, 1990) y LIBERTY (Dawson *et al.*, 1998), respectivamente, que en base a parámetros de la vegetación, simulan un espectro continuo de curvas de reflectancia y transmitancia. A su vez, dichos modelos pueden ser invertidos, por lo que si se cuenta con un instrumento óptico capaz de obtener la reflectancia en el rango de longitudes de onda entre los 400 y 2.500 nm, se podrían entregar los parámetros, físicos y químicos, de entrada que exige el modelo para su funcionamiento (Dawson *et al.*, 1999; Jacquemoud y Baret, 1990; Jacquemoud *et al.*, 1996). Un esquema del proceso de dispersión de la luz al interior de las hojas para cada modelo se puede encontrar en la Figura 2.29, mientras que los parámetros que pide cada modelo para su ejecución se pueden encontrar en la Tabla 2.2.

2. Nivel de Dosel.

Al momento de construir un modelo que busque explicar la interacción de la reflectancia a nivel del dosel, la hoja debe ser la unidad básica de medida (Lillesaeter, 1982). Bajo dicha primicia, se desarrolla el modelo SAIL (*Scattering by Arbitrarily Inclined Leaves*), que ha sido ampliamente

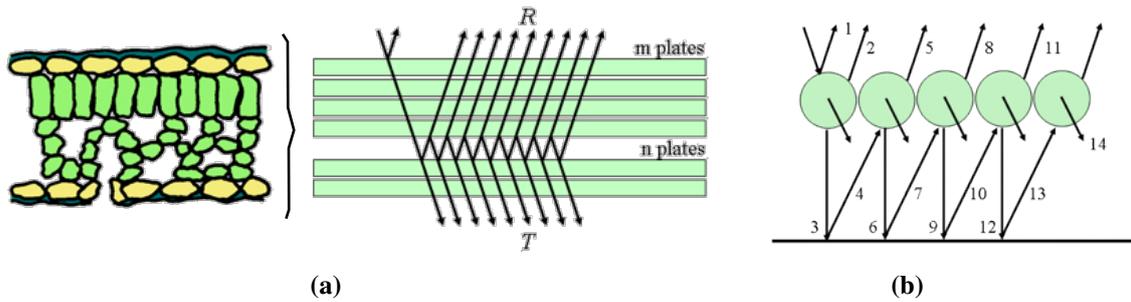


Figura 2.29: Modelos de transferencia radiativa a nivel de hoja (a) *Generalized Plate Model* (PROSPECT) y (b) *Compact Spherical Particle Model* (LIBERTY).

Fuente: Jacquemoud y Ustin (2008).

Tabla 2.2: Parámetros de entrada de los modelos PROSPECT y LIBERTY.

Fuente: *OpticLeaf* (2015b) y Dawson *et al.* (1998).

PROSPECT 5	LIBERTY
Estructura Interna (N)	Contenido de Clorofila
Contenido de Clorofila (C_{a+b})	Contenido de Agua
Contenido de Carotenoides	Contenido de Nitrógeno
Pigmentos Café	Contenido de Lignina
Equivalent Water Thickness (EWT)	Contenido de Celulosa
Leaf Mass per Area (LMA)	Promedio diámetro celular interno
	Espacio de aire intracelular
	Espesor de la hoja
	Absorción de la línea de base
	Área específica de la hoja (SLA)

utilizado por la comunidad científica en estudios a este nivel, dado que a partir de los parámetros que se darán a conocer a continuación, entrega un espectro continuo de reflectividad del dosel (Jacquemoud y Baret, 1990; Verhoef, 1984).

Los principales parámetros de entrada del modelo son:

- Las propiedades ópticas de una hoja (reflectividad (ρ) y transmisividad (τ)). Dichas propiedades se resumen en la expresión (2.13), en donde se tiene la reflectancia espectral de N hojas, con $\rho < 1$ (Lillesaeter, 1982).

$$\lim_{n \rightarrow \infty} \rho_N = \rho_\infty = \frac{\tau}{1 - \tau^2} \quad (2.13)$$

- Parámetros relativos a la geometría del dosel.
- Reflectancia del suelo.
- Leaf Area Index (LAI)
- Otros.

Posteriormente, el modelo SAIL incorpora los efectos del *Hotspot* (un resultado de la transferencia radiativa bidireccional; Kuusk, 1985), y pasa a llamarse SAILH. Con esta actualización se da un segundo paso a la hora de estudiar la anisotropía de la reflectancia de la vegetación, ya que además se considera la estructura tridimensional interna de la cubierta. Es decir, a pesar de estar

considerando una cubierta homogénea, el efecto de auto-sombra de la vegetación, produce que la reflectancia depende de la diferencia entre el ángulo de observación y el de iluminación. De esta forma, si se observa desde una dirección igual o cercana a la dirección de iluminación, se verán iluminadas todas las hojas de la vegetación (Berjón, 2007).

2.2.3.3.1 Bases de datos

En la literatura se encontraron bases de datos de muestras tomadas en terreno y analizadas en laboratorio. El fin de estas bases de datos es proveer información global de los diferentes tipos de vegetación y cómo éstos pueden variar en distintos ambientes. En cuanto al análisis de laboratorio, básicamente se procede a realizar un análisis espectral de las muestras, se secan, se les calcula la cantidad de clorofila, etc. La idea es que sean lo más completas posibles para así ayudar a mejorar la información. Dentro de las bases de datos, se encuentran algunas como LOPEX93 (Hosgood *et al.*, 1994), CALMIT (Gitelson *et al.*, 1998; Gitelson y Merzlyak, 1998), ANGERS (Recolectada en 2003 en plantas temperadas en INRA – Instituto Nacional de Investigación Agronómica de Angers, Francia) y HAWAII (Recolectadas en 2007, Hawaii (USA)). Las bases de datos de LOPEX93 y ANGERS se pueden encontrar en OpticLeaf (2015a).

Dichas bases de datos han sido ampliamente utilizadas por PROSPECT. Como se dijo anteriormente, PROSPECT es un modelo de transferencia radiativa, el cual está basado en el modelo generalizado por Allen *et al.* (1970), que representa las propiedades ópticas de las hojas de las plantas desde los 400 hasta los 2.500 nm. Este modelo estima la reflectancia de la vegetación en dicho rango de longitudes de onda mediante la entrada de ciertos parámetros tales como EWT (*Equivalent Water Thickness*), contenido de Clorofila a y b (C_{a+b}), contenido de carotenoides, masa de la hoja por unidad de área (LMA – *Leaf Mass per Area*), entre otros. PROSPECT ha sido mejorado continuamente (Feret *et al.*, 2008; Jacquemoud *et al.*, 1996), a la fecha, según la última actualización de la página (13 de Octubre de 2015), tiene más de 2.648 referencias relacionadas (OpticLeaf, 2015c), y ha sido utilizado exhaustivamente en la literatura para realizar, por ejemplo, estudios en relación al contenido de humedad de los combustibles y simular reflectancias a nivel de la hoja (Bowyer y Danson, 2004; Danson y Bowyer, 2004; Jacquemoud y Baret, 1990; Jacquemoud *et al.*, 1995, 1996; Ustin *et al.*, 1998).

La plataforma de PROSPECT se puede encontrar en OpticLeaf (2015b), en donde sólo hay que ingresar los parámetros que pide el modelo y arroja como resultado los valores de reflectancia (y transmisividad) a una resolución espectral de 1 nm entre los 400 y 2.500 nm. Cabe destacar que es por lo mismo que la base de datos de LOPEX93 ha sido ampliamente utilizada, ya que cuenta con más de 331 muestras de hojas en 45 especies distintas de Italia y, para cada muestra, existen todos los parámetros (y más) de los que se piden como parámetros de entrada para PROSPECT. Un ejemplo con algunas muestras de la base de datos de LOPEX93 y posterior simulación con PROSPECT se puede apreciar en el Anexo D.

2.2.4 Índices espectrales

Primero que todo, hay que establecer los parámetros o rangos de los anchos de banda que se encuentran en la literatura. Esto es puesto que si se habla, por ejemplo, de la banda azul, se puede encontrar textos en donde la establezca entre los 400 a 500 nm, y no solo eso, cada sensor de algún satélite presenta rangos distintos de longitudes de onda. Por ejemplo, la misión Landsat 7 utiliza como el canal azul la banda 1 (en el sensor ETM+), que corresponde a la banda que adquiere rangos de longitudes de onda entre los 450 – 520 nm (NASA, 2015a), mientras que el satélite SPOT-Vegetation sitúa la banda azul entre los 430 – 470 nm (SPOT-Vegetation, 2015). Ahora bien, se entiende que los datos fluctúan entre ciertos rangos, así, se establecerá que:

Tabla 2.3: Bandas aproximadas del espectro y de los sensores remotos.

Fuente: Elaboración propia por medio de Chuvieco (2010).

Banda	Rango (longitud de onda, λ)	Utilidad
Espectro Visible		
Azul	400 – 500 nm	Es la única radiación electromagnética perceptible por el ojo humano.
Verde	500 – 600 nm	
Rojo	600 – 700 nm	
Infrarrojo Cercano		
NIR ^a	700 – 1.200 nm	Es de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.
Infrarrojo Medio		
SWIR ^b	1.200 – 2.500 nm	Resulta ser una región idónea para estimar el contenido de humedad en la vegetación o los suelos.
MIR ^c	2.500 – 8.000 nm	Es determinante para la detección de focos de alta temperatura (incendios o volcanes activos) y la estimación de algunos gases atmosféricos.
Infrarrojo Lejano o Térmico		
TIR ^d	8.000 – 14.000 nm	Incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres.

^aNIR = Near Infrared (Infrarrojo cercano)

^bSWIR = Short Wave Infrared (Infrarrojo de onda corta)

^cMIR = Middle Infrared (Infrarrojo medio)

^dTIR = Thermal Infrared (Infrarrojo térmico)

Tabla 2.4: Índices espectrales con sus correspondientes ventajas y contras.

Fuente: Elaboración propia.

Índice	Fórmula	Ventajas	Contras
NDVI[†]		<ul style="list-style-type: none"> - Es sensible a cambios en variaciones del LAI (<i>Leaf Area Index</i>) y a la producción de clorofila (Blackburn y Milton, 1995; Running <i>et al.</i>, 1995). - Es útil para estimar el estrés hídrico de algunos cultivos (Ajai <i>et al.</i>, 1983; Tucker, 1980). - Se ha utilizado por algunos autores para clasificar tipos de combustibles (Burgan <i>et al.</i>, 1998; McKinley <i>et al.</i>, 1985; Miller y Johnston, 1985; Riaño <i>et al.</i>, 2002; Van Wagtendonk, 1997; Van Wagtendonk y Root, 2003). - Es un buen indicador de clorofila y LAI (Ceccato <i>et al.</i>, 2003). - Sirve de intermediario para el asesoramiento de varios parámetros biofísicos, como: la cubierta verde, biomasa, LAI, y a la fracción de absorción de la radiación activa de fotosíntesis (fAPAR – <i>Fraction of absorbed photosynthetically active radiation</i>) (Asrar <i>et al.</i>, 1984; Huete <i>et al.</i>, 2002; Sellers, 1985; Tucker, 1979). - En lugares con cubiertas de alta de vegetación, el NDVI funciona mejor que el WdVI (<i>Weighted Difference Vegetation Index</i>) (Qi <i>et al.</i>, 1994). - Se ha utilizado para estimar las cantidades de dos tipos de biomasa (AGB: <i>aboveground biomass</i>; BGB: <i>belowground biomass</i>) en praderas montañosas, resultando ser un buen predictor de ellos en comparación con el MSAVI y el EVI (Huang <i>et al.</i>, 2013). 	<ul style="list-style-type: none"> - Es sensible al brillo del suelo (Gilabert <i>et al.</i>, 1997). - Se ve afectado por el sistema de raíces (Peñuelas <i>et al.</i>, 1997; Piñol <i>et al.</i>, 1998). - Ha sido cuestionado en cuanto a su capacidad para estimar el contenido de humedad de la vegetación (Hunt Jr y Rock, 1989; Westman y Price, 1988). Cabe destacar que, por lo mismo, es que Hunt Jr y Rock (1989) propusieron el MSI (<i>Moisture Stress Index</i>). - No provee una estimación directa del contenido de agua (Ceccato <i>et al.</i>, 2003). - Presenta problemas con la presencia de nieve (Huete <i>et al.</i>, 2002). - Se ve afectado por cambios estacionales del ángulo de elevación solar cuando la vegetación es poco densa (Goward y Huemmrich, 1992; Pinter Jr <i>et al.</i>, 1985; Verrelst <i>et al.</i>, 2008). - Ceccato <i>et al.</i> (2001) discuten sobre el supuesto de la relación de la clorofila para estimar la humedad de la vegetación, dando a conocer que dicho supuesto no se puede utilizar indiscriminadamente para todas las especies por el “Leaf level” (nivel de hoja). - En sectores con cubiertas bajas de vegetación, el NDVI se ve fuertemente afectado (Qi <i>et al.</i>, 1994).
Normalized Difference Vegetation Index Rouse <i>et al.</i> (1973)	$\frac{NIR_t - RED_t}{NIR_t + RED_t}$	<ul style="list-style-type: none"> - Ha demostrado ser mucho más sensible a la concentración de clorofila, en un amplio rango de variaciones de ésta, que el “red” NDVI, y permite una estimación precisa de la concentración de los pigmentos (Gitelson <i>et al.</i>, 1996). 	<ul style="list-style-type: none"> - Se puede ver afectado por la iluminación y la arquitectura del dosel (Gitelson <i>et al.</i>, 1996).
GNDVI Green Normalized Difference Vegetation Index Gitelson <i>et al.</i> (1996)	$\frac{NIR_t - GREEN_t}{NIR_t + GREEN_t}$		

[†]La banda del NIR corresponde a la banda 2 del sensor modis, mientras que la banda Green corresponde a la banda 4 (NASA, 2015c).

- Es conocido por tener una fuerte relación al contenido de agua de las plantas (Gao, 1996).
- Es menos sensible a la dispersión atmosférica que el NDVI (Gao, 1996; JRC, 2011).
- En el rango de λ entre 0,9 a 2,5 μm se domina la absorción de agua (en la vegetación verde) por lo que resulta ser un índice útil por las bandas que utiliza (Gao y Goetz, 1995).
- Por medio de este índice se puede inferir el EWT (*Equivalent Water Thickness*) en áreas totalmente cubiertas de vegetación vigorosa (Gao y Goetz, 1995).
- Ha arrojado buenos resultados en la estimación del FMC (*Fuel Moisture Content*) en sectores con alto contenido de arbustos (*Shrublands*) (?).
- No se satura ante la presencia de bajos LAI (*Leaf Area Index*), como le sucede al NDII y al NDVI (Hunt Jr et al., 2013b).

NDWI

Normalized
Difference
Water Index

$$\frac{\rho(0, 86\mu\text{m}) - \rho(1, 24\mu\text{m})}{\rho(0, 86\mu\text{m}) + \rho(1, 24\mu\text{m})}$$

Gao (1996)

- Es muy sensible a la reflectancia del suelo, por lo que no funciona bien en cubiertas vegetales poco densas (dosel arbóreo) (Gao, 1996).
- El autor de éste índice propone que para el entendimiento y la totalidad de las limitaciones del NDWI, éste debiese ser testeado en laboratorio y medidas en terreno de la reflectancia espectral del dosel vegetal con data AVIRIS (*Airborne Visible IR Imaging Spectrometer*).

- Sirve para ajustar las diferencias en la radiancia a través del paisaje, es decir, permite comparar áreas de un determinado lugar con otra (Rock et al., 1986, 1985).
- Fue correlacionado linealmente con RWC (*Relative Water Content*) de algunas especies, obteniendo buenos resultados (Ceccato et al., 2001; Hunt Jr et al., 1987).
- En torno a la aplicación del MSI para el estudio de las especies realizado por Hunt Jr et al. (1987), se llega a la conclusión de que existe una relación entre el MSI y el EWT (*Equivalent Water Thickness*) (Hunt Jr y Rock, 1989).
- Tiene buenas correlaciones con el LAI (*Leaf Area Index*) (Hunt Jr y Rock, 1989)

MSI

Moisture
Stress Index

$$\frac{\rho(0, 82\mu\text{m}) - \rho(1, 6\mu\text{m})}{\rho(0, 82\mu\text{m}) + \rho(1, 6\mu\text{m})}$$

Hunt Jr y Rock
(1989)

- Si el RWC (*Relative Water Content*) es $> 0,5$, el MSI no se puede utilizar. Habría que esperar hasta que la planta reduzca su cantidad de agua (Hunt Jr y Rock, 1989).
- Podría no ser capaz de detectar las etapas incipientes de estrés hídrico para todo tipo de vegetación (Hunt Jr y Rock, 1989).
- No es suficientemente sensible para determinar cambios en EWT que ocurren en doseles con estrés hídrico a un LAI constante (Hunt Jr y Rock, 1989).

- Es una variación del NDVI que utiliza la banda SWIR en vez de la banda RED (Hunt Jr y Rock, 1989).
- Está altamente correlacionado con el contenido de agua del dosel arbóreo (Hunt Jr y Rock, 1989).
- Se relaciona casi linealmente con el EWT (*Equivalent Water Thickness*) ($r^2 = 0,818$) al utilizar la banda 5 del LANDSAT TM y valores del NIR de $0,82 \mu\text{m}$ (Hunt Jr y Rock, 1989).
- El NDII calculado en el sensor LANDSAT Thematic Mapper (TM) para determinar el FMC (*Fuel Moisture Content*) de algunas especies resultó tener correlaciones altas para algunas de ellas. En el caso del pasto, tuvo una correlación de 0,855 con la banda 5 del TM, mientras que la mayor correlación obtenida en la banda 7 del TM con NDII, fue de 0,828 en el caso de la especie *R. Officinalis* (Romero) (Chuvieco *et al.*, 2002).
- Permite realizar mapas de FMC (*Fuel Moisture Content*) (Chuvieco *et al.*, 2002).
- Tiene relación con el VWC (*Vegetation Water Content*) (Jackson *et al.*, 2004).
- En un estudio realizado por Sow *et al.* (2013), la mejor correlación obtenida entre varios índices y el FMC (*Fuel Moisture Content*) fue el NDII de las bandas 2 y 6 del sensor Modis. A su vez, presentó, también, la mayor correlación con el EWT ($r^2 = 0,9$) junto con el GVMÍ (*Global Vegetation Moisture Index*).
- Ha arrojado buenos resultados en la estimación del FMC (*Fuel Moisture Content*) en sectores con alto contenido de arbustos (*Shrublands*) (Yebara *et al.*, 2008b).
- Se ha relacionado mejor con el contenido de agua que con el FMC, mientras que el NDII/NDMI se correlacionó mejor con el FMC que con el contenido de agua, llegando a correlaciones de hasta $R^2 = 0,853$ (Wang *et al.*, 2013).

$$\frac{NIR_t - SWIR_t}{NIR_t + SWIR_t}$$

NDII[‡]

Normalized
Difference
Infrared Index

Hardisky *et al.*
(1983)

$$\frac{\rho(0,85\mu\text{m}) - \rho(1,65\mu\text{m})}{\rho(0,85\mu\text{m}) + \rho(1,65\mu\text{m})}$$

[‡]Las bandas del SWIR definidas para el NDII son las correspondientes a las bandas 5 o 7 del Landsat TM (Chuvieco *et al.*, 2002; USGS, 2016). Wang *et al.* (2013) establecen que las bandas se concentran en los: NIR: 860 nm, mientras que en el SWIR: 1.650 nm.

- No ha ofrecido buenos resultados para la estimación del FMC (*Fuel Moisture Content*) en pastizales (Yebra *et al.*, 2008b).
- El estudio que realizó Gitelson *et al.* (2002), incluye solo dos especies, por lo que ellos reconocen que ante diferentes especies, iluminación, arquitectura del dosel, propiedades del suelo y otros factores, puede disminuir –potencialmente– la precisión del índice VARI.
- Puede ser menos sensible que el NDWI a las variaciones espaciales en lugares de vegetaciones chaparral (*Shrublands* – arbustos) (Stow *et al.*, 2005).

- Ha proveído muy buenos resultados en la estimación del FMC (*Fuel Moisture Content*) en especies de *C. Ladanifer* (Jara Pringosa) (Yebra *et al.*, 2008b).
- Presenta una sensibilidad muy baja a los efectos atmosféricos, permitiendo una medición del VF (*Vegetation Factor* [%]) con un error menor del 10 %, una correlación mayor de 0,95 y, al ser muy sensible a los cambios del VF, VARI puede captar VF desde sus valores de 0 al 100 %, algo que el NDVI no puede, ya que solo capta sensiblemente hasta el 60 % de VF (Gitelson *et al.*, 2002).
- En rangos de VF entre 50 al 100 %, para especies de trigo y choclo, VARI obtuvo las mayores correlaciones (entre NDVI y GARI) (Gitelson *et al.*, 2002).

VARI[†]

Visible
Atmospherically
Resistant Index

$$VARI_{GREEN} = \frac{GREEN_t - RED_t}{GREEN_t + RED_t - BLUE_t}$$

Gitelson *et al.*
(2002)

$$VARI_{RED-EDGE} = \frac{RED_{EDGE} - 1,7 \cdot RED - 0,7 \cdot BLUE}{RED_{EDGE} + 2,3 \cdot RED - 1,3 \cdot BLUE}$$

- El estudio realizado por Gitelson *et al.* (2002) que utilizó las bandas azul (0,47 – 0,49 μm), rojo (0,66 – 0,68 μm) y verde ($\sim 0,55 \mu m$) o la banda RED-EDGE ($\sim 0,70 \mu m$) parecen ser mejores indicadores para estimar el VF (*Vegetation Factor*) del trigo y choclo que las bandas del RED/NIR que son las comúnmente utilizadas.
- Stow *et al.* (2005) compararon resultados del VARI con el NDWI para monitorear el FMC (*Fuel Moisture Content*) con sensor Modis, donde el primero obtuvo mejores correlaciones con el FMC que el segundo para 2 de los 3 sectores estudiados, así, ellos concluyen que el VARI puede ser un buen predictor del FMC.

VI_{GREEN}

Vegetation
Index (Green)

$$\frac{NIR_t - RED_t}{NIR_t - RED_t}$$

Tucker (1979)

- Tucker (1979) realizó un experimento con varios índices para monitorear la vegetación, donde obtuvo los mejores resultados utilizando la región NIR y RED del VI_{GREEN}.
- Es un índice sensible a la actividad fotosintética de la vegetación presente en el dosel de las plantas (Tucker, 1979).

[†]Gitelson *et al.* (2002) definen la banda RED cercana a los 670 nm, la banda GREEN cercana a los 550 nm y la banda BLUE entre los 400 y 500 nm. Stow *et al.* (2005) utilizan el sensor Modis, en donde la banda GREEN, RED y BLUE corresponden a las bandas 4, 1 y 3, respectivamente, del sensor.

- EVI**[†]
- Enhanced Vegetation Index
- Huete *et al.* (2002)
- $$\frac{G \cdot (\rho_{NIR} - \rho_{RED})}{\rho_{NIR} + C_1 \cdot \rho_{RED} - C_2 \cdot \rho_{BLUE} + L}$$
- Ha arrojado buenos resultados para la estimación del FMC (*Fuel Moisture Content*) en pastizales (Yebra *et al.*, 2008b).
 - Ha tenido resultados positivos en experimentos en Brasil, donde se monitoreó la quema de biomasa en condiciones de aerosoles pesados (Miura *et al.*, 1998).
 - Mientras que el NDVI es sensible a la clorofila, el EVI responde mejor a las variaciones estructurales del dosel vegetal, incluyendo el LAI, tipo de dosel, fisonomía de las plantas, y la arquitectura del dosel (Gao *et al.*, 2000).
 - Se creó con la finalidad de optimizar la sensibilidad de la señal de la vegetación en regiones con alta densidad de la misma, para mejorar el monitoreo de ésta y reducir –a su vez– los efectos atmosféricos (Huete *et al.*, 2002).
 - Se encontró que EVI tiene una correlación más lineal que el NDVI con el LAI en campos de cultivo (Boegh *et al.*, 2002).
 - EVI cuenta con una banda azul (*BLUE*) que permite reducir el ruido y la incertidumbre asociada a las altas variaciones de los aerosoles en la atmósfera (Jiang *et al.*, 2008).
 - Cuenta con el legado del índice SAVI, por lo que EVI provee resultados con resistencia a los suelos (Huete *et al.*, 2002; Jiang *et al.*, 2008).
 - En los resultados del experimento realizado por Huete *et al.* (2002), se encontró que los valores del EVI, a diferencia del NDVI, exhibieron un perfil de cambio de temporada más suave, con un perfil temporal más simétrico con un peak de vegetación más estrecho y definido.
- Se ve fuertemente afectado, al igual que el NDVI, por los cambios estacionales y diurnos por el ángulo de elevación solar cuando la vegetación es poco densa (Sims *et al.*, 2008, 2006).
 - Se encontró que el factor “L” (ajuste de fondo del dosel) propuesto por Huete *et al.* (2002) afecta al EVI en el sentido que lo hace más sensible a las condiciones topográficas, a diferencia del NDVI, que no le sucede (Matsushita *et al.*, 2007).
 - Se ve afectado –considerablemente– por el ángulo de visión del sensor, que, según Sims *et al.* (2011), podría deberse a los cambios en el ángulo zénit solar. De esta forma, a mayor sensibilidad del ángulo por parte de EVI, resulta muy importante tener extremo cuidado al corregir para los efectos BRDF (*Bi-directional Reflectance Distribution Function*).

[†] ρ corresponde a la corrección atmosférica de las reflexiones de la superficie, C_1 y C_2 corresponden a los coeficientes de correcciones para la resistencia de aerosoles, L es el ajuste del fondo del dosel, en donde dichos valores se pueden encontrar en el estudio de Huete *et al.* (2002). Las bandas utilizadas corresponden a las del sensor Modis, en donde ρ_{NIR} , ρ_{RED} y ρ_{BLUE} corresponden a las bandas 2, 1 y 3, respectivamente, del sensor (NASA, 2015c).

(Continuación
EVI)

- EVI, a diferencia del NDVI, es muy sensible a la estructura del dosel de las hojas tipo aguja (*needle-leafs*) y las hojas anchas (*broadleafs*) (Huete *et al.*, 2002).
- EVI, a diferencia del NDVI, cuenta con SAVI, por lo que resiste mejor a los efectos de la nieve (Huete *et al.*, 2002).
- Puede indicar/medir el estrés hídrico, en un plazo mayor o igual a 16 días (Sims *et al.*, 2008).
- Ha resultado ser más útil que NDVI para estimar el intercambio de carbono en vegetación (Sims *et al.*, 2008).
- Ha arrojado buenos resultados en la estimación del FMC (*Fuel Moisture Content*) en sectores con alto contenido de arbustos (*Shrublands*) (Yebra *et al.*, 2008b).
- Éste índice es conveniente para obtener datos de la cantidad de agua en la vegetación cuando el LAI es ≥ 2 (Ceccato *et al.*, 2002b).
- Expresa sus resultados del contenido de agua en la vegetación en cantidades de agua en el dosel por unidad de área (EWT *CANOPY*) y minimiza los efectos de las perturbaciones geofísicas y atmosféricas (Ceccato *et al.*, 2002b).
- Se han obtenido buenos resultados con el EWT *CANOPY* medido en el campo, donde hubo una correlación de 0,93 para todos los sitios estudiados por Ceccato *et al.* (2002b).
- Ceccato *et al.* (2002b) estiman que el GVMi puede ser de útil información para el contenido de agua en la vegetación para los gestores de parques nacionales, bosques y agricultura para realizar calendarios contra incendios y, de esta forma, gestionar el riesgo de ocurrencia de ellos.
- En el experimento realizado por Danson y Bowyer (2004), el GVMi obtuvo la segunda mayor correlación para la estimación del EWT luego del NDWI.
- En lugares donde la vegetación es escasa (*sparsely vegetated area*), donde el LAI es menor que 2, no hay información de la utilización del GVMi (Ceccato *et al.*, 2002b).
- Se ve afectado por la reflectancia del suelo (Ceccato *et al.*, 2002b).
- No provee información sobre el contenido de agua expresado como un porcentaje de agua por cantidad de biomasa (*Moisture content*), mas solo provee información del contenido de agua en la vegetación por unidad de área o EWT *CANOPY* (Ceccato *et al.*, 2002b).

GVMi

Global
Vegetation
Moisture Index

$$\frac{(NIR_r + 0, 1) - (S WIR + 0, 02)}{(NIR_r + 0, 1) + (S WIR + 0, 02)}$$

Ceccato *et al.*
(2002b)

- Tiene alta correlación con el PWC (*Plant Water Concentration*) de determinadas especies mediterráneas (Peñuelas *et al.*, 1997).
- Tiene relación con el NDVI, para corregir el WI por los efectos del primero. Usualmente se utilizan juntos (Peñuelas *et al.*, 1997).
- En el experimento realizado por Danson y Bowyer (2004), las mayores correlaciones obtenidas como “inputs” del modelo de reflectancia *Prospect*, tanto para las “*gaussian*” como para las “*uniform*”, fueron del WI para la estimación del FMC (*Fuel Moisture Content*).
- En otros experimentos (Dawson *et al.*, 1999) los mejores resultados o los métodos más robustos para estimar el contenido de agua del dosel de la vegetación en una región espectral entre los 0,40 μm y los 1,00 μm , fueron obtenidos por el WI.
- En lugares con LAI entre 0 y 0,5, un valor de LAI=1 disminuye casi en su totalidad los efectos del suelo (Huete, 1988).
- Para lugares con mayores densidades de vegetación (LAI=1), el valor de L óptimo encontrado por Huete (1988) fue de 0,75. Por ende, se establece que a una mayor densidad o vigorosidad vegetal, menor es el valor de L.
- Para valores entre $0,25 \leq L \leq 1$, las influencias del suelo se reducen considerablemente al compararlo con el NDVI (Huete, 1988).
- Ha proveído buenos resultados en la estimación de los FMC (*Fuel Moisture Content*) de pastizales (?).
- En el caso del estudio realizado por Huete (1988), el SAVI (L=0,5) brindó buenos resultados al minimizar el ruido del suelo en los doseles de pastizales de hoja corta y algodón de hojas extensas.
- Tanto el WI como el WI/NDVI ofrecen una simple, fácil e instantánea –pero de algún modo *ruidoso* (bajo r^2)–, en la estimación del PWC. El problema del ruido viene dado al realizar múltiples mediciones o que las mediciones fueron realizadas repetidamente en las mismas plantas, por lo que Peñuelas *et al.* (1997) proponen utilizar un radiómetro que solo mide la reflectancia en bandas angostas centradas en los 0,680, 0,900 y 0,970 μm , el cual puede medir inmediatamente el NDVI y WI, y, con una buena calibración, provee el PWC (*Plant Water Concentration*) en cuestión de segundos.
- Huete (1988) propone que si bien un valor promedio y útil a utilizar de L es 0,5, no es un valor ideal (aunque ? lo utilizaron con dicho valor), ya que la naturaleza de la interacción suelo-vegetación varía con la vigorosidad de la vegetación del sector.
- No funciona bien en todos los tipos de suelo. Por ejemplo, los suelos de color rojo o amarillentos se proyectan como regiones de vegetación al sensor, perjudicando o haciendo inútil éste índice Huete (1988).
- Huete (1988) recomienda, por el mismo punto anterior, tener un conocimiento o entendimiento de las propiedades espectrales del suelo para su comprensión, ya que el suelo es una variable muy dinámica.

WI

$$\text{Water Index} = \frac{\rho(0,90 \mu\text{m})}{\rho(0,97 \mu\text{m})}$$

Peñuelas *et al.* (1993, 1997)

SAVI†

$$\text{Soil-Adjusted Vegetation Index} = \frac{(NIR_t - RED_t) \cdot (1 + L)}{(NIR_t + RED_t + L)}$$

Huete (1988)

†L corresponde a un factor de ajuste propuesto por Huete (1988). Para L=0, el SAVI es equivalente al NDVI. Los valores del NIR y RED que se utilizaron corresponden a las bandas 2 y 1, respectivamente, del sensor Modis (Yebra *et al.*, 2013).

(Continuación
SAVI)

- Es menos sensible al contenido de clorofila que el NDVI y MSAVI (Haboudane *et al.*, 2004).
- A pesar de contar con una insensibilidad a los efectos de bajos niveles de clorofila, éste índice no es bueno para caracterizar áreas verdes en doses densos con LAI>4 (Haboudane *et al.*, 2004).
- Al utilizar en la expresión empírica de L el NDVI y el WDV, puede no ser la mejor función y puede no funcionar bien tipos de doses vegetales distintos a los de algodón (Qi *et al.*, 1994).
- En lugares donde la cubierta de la vegetación es alta, el NDVI resulta ser un mejor indicador que el WDV, ya que se ve menos afectado al efecto del suelo. Mientras que en lugares de cubiertas vegetales bajas el WDV resulta ser un mejor indicador ya que se ve menos afectado a la reflectancia del suelo (Qi *et al.*, 1994).
- Es muy sensible a los efectos atmosféricos (Broge y Leblanc, 2000; Gonsamo, 2010; Gonsamo y Chen, 2014).
- En cuanto al monitoreo para estimar el contenido de humedad de los suelos, el EVI presenta una ventaja ante el MSAVI, ya que el primero es capaz de remover el ruido de la atmósfera y del suelo (Zhang *et al.*, 2014a).

- La diferencia entre SAVI y MSAVI es que el segundo viene a reemplaza la constante "L" en la ecuación de SAVI con una función variable de L (Qi *et al.*, 1994).
- En primera instancia, el factor L se calcula como: $L = 1 - 2\gamma * NDVI * WDV$ (Weighted (IR) Difference Vegetation Index), pero, se propone que el resultado involucrado en la ecuación del MSAVI corresponde a un MSAVI₁, donde existe, a su vez, un MSAVI₀ = $[(NIR - RED) * (1 - L_0)] / (NIR + RED + L_0)$ que minimizaría el efecto del suelo. Así, se define otro valor de L definido por: $L_1 = 1 - MSAVI_0$, donde se puede decir, entonces:

$$\frac{NIR_t - RED_t}{NIR_t + RED_t + L} * (1 + L)$$

$$MSAVI_1 = \frac{(NIR - RED) * (2 - MSAVI_0)}{NIR + RED + 1 - MSAVI_0}$$

MSAVI

Modified Soil-
Adjusted
Vegetation
Index

Qi *et al.* (1994)

- De la ecuación anterior se obtiene que el proceso continuo para "n" veces está determinado por: $L_n = 1 - MSAVI_{n-1}$ (Qi *et al.*, 1994).
- En contraste con el índice SAVI, el MSAVI₁ disminuyó mucho más las influencias por el ruido del suelo, y la respuesta a los VI (Vegetation Indices) al porcentaje de áreas verdes se comporta más lineal (Qi *et al.*, 1994).
 - En el experimento realizado por Qi *et al.* (1994), el MSAVI eliminó toda sensibilidad al suelo, mientras que el SAVI presentó pequeñas sensibilidades al mismo.
 - MSAVI es un indicador más sensible a la cantidad de vegetación que el SAVI (Qi *et al.*, 1994).

(Continuación
MSAVI)

- En lugares de alta vegetación, el factor L tiende a 0, y el MSAVI se comportó como el NDVI, mientras que en lugares de baja vegetación, donde el factor L tiende a 1, el MSAVI se comportó como el PVI (*Plant Vegetation Index*) o el WDVI (Qi et al., 1994).
- En el mismo estudio (Qi et al., 1994) se utiliza un $MSAVI_2 = 0,5 * [2(NIR + 1) - \sqrt{(2NIR + 1)^2 - 8(NIR - RED)}]$ donde no aparece el factor L y que tuvo resultados muy similares al MSAVI₁.
- En vegetaciones densas caracterizadas por elevados LAI, el mejor indicador estimador de éste, en términos de la sensibilidad a los efectos del dosel vegetal, fue el MSAVI₂ (Broge y Leblanc, 2000). En otro estudio, realizado por Gonsamo y Chen (2014), se demostró la capacidad del MSAVI para estimar valores del LAI en series de tiempo.

- Entrega valores de 0 para suelos desnudos y cercano a 1 para LAI muy elevados (Baret et al., 1989).

- Para a=1 y b=0, TSAVI=NDVI.

- Parece ser una herramienta poderosa para evaluar el LAI (Baret et al., 1989).

- Teóricamente mejora la independencia a las propiedades ópticas del suelo si uno puede ajustarlo a líneas específicas del suelo del objetivo (Baret et al., 1989).
- Ha sido superior que el NDVI para estimar la robustez del “*canopy gap fraction*” en doses de remolachas azucareras (Baret et al., 1995).

- Se ha utilizado para disminuir los efectos de fondo (*background*), arrojando mejores resultados que el NDVI (Elvidge y Chen, 1995).

TSAVI†

Transformed
Soil Adjusted
Vegetation
Index

$$\frac{a * (NIR - a * RED - b)}{(RED + a * NIR - a * b)}$$

Baret et al. (1989)

†a corresponde a la pendiente de la línea del suelo (*soil line slope*): $d(\rho_{NIR})/d(\rho_{RED})$, y b es el intercepto de la línea del suelo (*soil line intercept*).

ARVI	<ul style="list-style-type: none"> - Se creó para ser utilizado con el sensor Modis de EOS (<i>Earth Observation System</i>) (Kaufman y Tanre, 1992). - Es, en promedio, 4 veces menos sensible a los efectos atmosféricos que el NDVI (Kaufman y Tanre, 1992). - En el estudio realizado por Kaufman y Tanre (1992) se habla, también, sobre el SARVI que incorpora, a su vez, una resistencia a los suelos (soil), definido como: $SARVI = (1 + L) * (NIR - RB) / (NIR + RB + L)$. 	<ul style="list-style-type: none"> - La complicación de éste índice se traduce en encontrar un solo valor de γ que reduce el efecto atmosférico significativo. Aunque, se puede dar que un solo valor pueda ser utilizado para toda aplicación de sensores remotos (Kaufman y Tanre, 1992). - La resistencia de ARVI a los efectos atmosféricos depende del tipo de suelo y a las propiedades radiativas de la atmósfera (Kaufman y Tanre, 1992). - Actúa mejor cuando el tamaño de las partículas de aerosol son de tamaño moderado a pequeñas (Kaufman y Tanre, 1992).
Atmospherically Resistant Vegetation Index	$\frac{\rho_{NIR} - \rho_{RB}}{\rho_{NIR} + \rho_{RB}}$ $\rho_{RB} = \rho_{RED} - \gamma(\rho_{BLUE} - \rho_{RED})$	
Kaufman y Tanre (1992)		
NMDI [†]		
Normalized Multi-band Drought Index	$\frac{\rho(860nm) - [\rho(1640nm) - \rho(2130nm)]}{\rho(860nm) + [\rho(1640nm) - \rho(2130nm)]}$	
Wang y Qu (2007)		
	<ul style="list-style-type: none"> - Sirve para monitorear la humedad del suelo y la vegetación (Wang y Qu, 2007). - Similar al NDWI y NDII, el NMDI utiliza el canal centrado en los $0,86 \mu m$, el cual es insensible a los cambios en el contenido de agua de las hojas, pero, a diferencia de contar con una sola banda de absorción de agua como los 2 primeros índices señalados, el NMDI utiliza la diferencia (<i>pendiente</i>) entre dos bandas que se enfocan en la absorción de agua ($1,64$ y $2,13 \mu m$) del suelo y la vegetación, ya que absorben agua en esas longitudes de onda (Wang y Qu, 2007). - Para lugares con vegetación moderada ($0,5 \leq LAI \leq 1$) el NMDI es sensible al contenido de agua en suelos y hojas (Wang y Qu, 2007). - Los resultados obtenidos por Wang y Qu (2007) sugieren que para lugares con suelos desnudos o baja vegetación ($LAI < 2$), un píxel se asignará como condición de suelo seco si el $NMDI \geq 0,7$, será “intermedio” si $0,6 \leq NMDI \leq 0,7$, y estará húmedo si el $NMDI < 0,6$ (Wang y Qu, 2007). 	<ul style="list-style-type: none"> - En lugares con $LAI \geq 2$, el desempeño del NMDI será similar al del NDWI y NDII (Wang y Qu, 2007).

[†] ρ representa la reflectancia aparente observada desde un sensor satelital (Wang y Qu, 2007).

(Continuación
NMDI)

- Se ha utilizado para detectar incendios forestales tanto para vegetación como para suelos. La diferencia radica que el $NMDI_{SOIL}=0,9-NMDI_{VEG}$, en donde el $NMDI_{VEG}$ corresponde al mismo señalado en la ecuación para éste índice. Si en ambos casos el $NMDI$ es ≤ 2 , entonces existen píxeles de fuego, mientras que si es > 2 , no hay píxeles de fuego. El $NMDI$ demostró ser el índice con mejor desempeño para discriminar entre píxeles con fuego entre el $NDWI$ y el NBR (*Normalized Burn Ratio*) y puede ser utilizado en zonas con diferentes características de doseles vegetales (*Wang et al., 2008*).
- Se ha utilizado como índice de humedad para el monitoreo del peligro de incendio con imágenes *Mobis*, donde su desempeño fue muy bueno: calzó con el 75 % de los incendios ocurridos para la temporada en análisis (*Chowdhury y Hassan, 2015*).
- Ha entregado mejores resultados que el $NDWI$ en la descripción estacional de las variaciones de humedad en la vegetación y en las condiciones de sequía (*Akther y Hassan, 2011*).
- En el estudio realizado por *Akther y Hassan (2011)*, de tres índices utilizados para predecir el peligro de incendios, se concluyó que el que tiene mejores capacidades es el $NMDI^a$.

Índice de Gitelson[†]

$$\frac{\rho(NIR)}{\rho(\lambda)} - 1$$

Gitelson et al. (2003)

- Tiene la capacidad de estimar la concentración de clorofila $a+b$ (C_{a+b}) a partir de un método no destructivo (*Gitelson et al., 2003*).
- Ha dado mejores resultados que varios otros creados por otros autores en cuanto al error cuadrático medio (RMSE en $\mu\text{mol m}^{-2}$) (*Blackburn, 1998; Chappelle et al., 1992; Datt, 1998; Gitelson y Merzlyak, 1994*).
- Tiene la posibilidad de utilizarse para calcular la cantidad de carotenoides de la muestra (*Gitelson et al., 2003*).

- Se ha validado sólo con unos pocos tipos de vegetación (en hojas de *mapple, chestnut, beech y wild vine*; *Gitelson et al., 2003*).

[†]*Gitelson et al. (2003)* definen la reflectancia en el NIR (ρ_{NIR}) a aquella comprendida entre los 750 y 800 *mm*, mientras que la reflectancia ρ_{λ} la establecen entre los 695 y 740 *mm*.

2.2.4.1 Metodología para crear índices espectrales

Tal como se observó en la [Sección 2.2.4](#), existen una serie de índices espectrales con distintos objetivos y funciones. De esta forma, en la literatura se encontraron una gran variedad de formas para la construcción de índices espectrales. A continuación se expondrán dos metodologías que se hallaron para la elaboración de estos.

- **Metodología 1:**

Esta herramienta fue propuesta por [Mobasheri y Fatemi \(2013\)](#), en el que se señala que la construcción de un índice espectral se debe realizar con alguna de las tres fórmulas propuestas ([2.14](#), [2.15](#) y [2.16](#)) para todas las posibles combinaciones de reflectancia correspondiente a un amplio rango de longitudes de onda. El fin es encontrar aquella expresión que maximice el coeficiente de determinación (R^2) o, de forma análoga, que minimice el error cuadrático medio (RMSE – *Root Mean Square Error*).

$$X = a (R_{\lambda_i} - R_{\lambda_j}) + b \quad i, j = 1, 2, \dots, i \neq j \quad (2.14)$$

$$X = a \left(\frac{R_{\lambda_i}}{R_{\lambda_j}} \right) + b \quad i, j = 1, 2, \dots, i \neq j \quad (2.15)$$

$$X = a \left(\frac{R_{\lambda_i} - R_{\lambda_j}}{R_{\lambda_i} + R_{\lambda_j}} \right) + b \quad i, j = 1, 2, \dots, i \neq j \quad (2.16)$$

Donde X es la variable a estimar, ρ_{λ_i} es la reflectancia en la longitud de onda λ_i , ρ_{λ_j} es la reflectancia en la longitud de onda λ_j , y a, b son los coeficientes de la regresión. Cabe destacar que el formato que presentan las ecuaciones anteriores son como la mayoría de los índices espectrales existentes. Por ejemplo, la ecuación ([2.16](#)) se asemeja a índices tales como el NDVI, NDWI, ARVI, entre otros, por la diferencia normalizada de regiones del espectro; mientras que la ecuación ([2.15](#)) se asemeja a la del Water Index (WI) como resultado del cociente entre dos reflectancias a determinadas longitudes de onda.

- **Metodología 2:**

La segunda metodología es aquella propuesta por [Datt \(1998\)](#), la cual señala que lo primero que se debe hacer es construir un correlograma, que consiste en la correlación de datos estadísticos (en este caso coeficiente de determinación vs longitud de onda – R^2 vs λ) entre los valores de la propiedad a estimar y la reflectancia para las diversas longitudes de onda. De esta forma, un correlograma contará con regiones del espectro (longitudes de onda) con altos y bajos valores de R^2 . El índice se construye, entonces, utilizando el cociente entre la reflectancia de una longitud de onda insensible y la reflectancia de una longitud de onda sensible (ver la expresión [2.17](#)).

$$R = \frac{\rho(\lambda)_{Insensible}}{\rho(\lambda)_{Sensible}} \quad (2.17)$$

Si bien en la presente sección se consideraron dos metodologías para crear índices, existen variadas formas de realizarlo. Ejemplos de algunas otras serían el caso de la Regresión de Mínimos Cuadrados Parciales ([Ullah et al., 2014](#)), Análisis de Sensibilidad Global (GSA – [Ceccato et al., 2002b](#)), entre otros.

2.3. Biomasa como combustible de Incendios Forestales

El fuego es el resultado del proceso químico denominado combustión. Para que el fuego se de, se requiere de ciertos “parámetros de entrada”, los cuales son la presencia de una sustancia combustible a una temperatura suficientemente alta (temperatura de ignición) para provocar la combustión y la presencia de oxígeno para mantenerla (CONAF, 2011, pág. 11).

Un incendio forestal puede definirse como el fuego que se propaga, sin control, en un sistema forestal y cuya quema no cumple funciones ni objetivos de gestión, por lo que requiere trabajos de extinción. Se trata de un suceso no deseado en el que se producen una serie de consecuencias económicas y ecológicas calificadas como daños y perjuicios (Martínez, 2001; Salas y Cocero, 2004). De esta forma cabe destacar que el combustible del cual se alimenta el fuego para propagarse y mantenerse es la vegetación, tanto viva como muerta (CONAF, 2011).

En Chile, la Comisión Nacional Forestal (CONAF) ha realizado un arduo trabajo para determinar las causalidades de los incendios forestales a nivel nacional, de donde se puede apreciar que sobre el 90 % de estos, entre el período 2003–2015, son generados por el humano (CONAF, 2016a).

A su vez, hay que destacar que existen diversos tipos de incendios forestales, los que se pueden clasificar como (CONAF, 2011):

1. **De superficie:** Tienden a ser los más comunes y queman el sotobosque (matas, arbustos, helechos, etc). La velocidad de propagación de estos dependerá del tipo y condición del combustible (vegetación), topografía y tiempo atmosférico del sector.
2. **De corona (Crown Fires):** Se originan producto de un fuego de superficie, que luego avanza por las copas de los árboles (dosel o, del inglés, *canopy*). La velocidad de propagación y desprendimiento calórico es alta. Los combustibles que alimentan estos tipos de incendios son principalmente los de vegetación viva, y bastante poco se sabe acerca de la combustión de este tipo de combustibles (McAllister *et al.*, 2012). A su vez, se entienden como los incendios más peligrosos y catastróficos (Butler *et al.*, 2004; Scott y Reinhardt, 2001). De hecho, la conclusión a la que llegaron Butler *et al.* (2004) es que en este tipo de incendios los flujos de calor radiante y máximas temperaturas pueden alcanzar los 290 [kWm^{-2}] y 1.330°C, respectivamente, con un flujo de calor radiante medio de 200 [kWm^{-2}].
3. **Subterráneos:** El fuego quema las raíces, las capas de humus del suelo y la micro-fauna. Se caracteriza por una combustión sin llamas, con una baja velocidad de propagación del fuego.

Ahora bien, cabe destacar que en un incendio forestal se suelen observar una combinación de estos tres tipos de incendios (CONAF, 2011).

En el ámbito de los incendios forestales, se define como combustible a la vegetación, tanto viva como muerta, susceptible de arder que son necesarias como variables de entrada para los modelos de predicción del comportamiento del fuego (Anderson, 1982; Cocero *et al.*, 2004; Scott y Burgan, 2005). En cuanto a los tipos y modelos de combustible, Andrews y Queen (2001) establecen que un modelo de combustible describe las características físicas del combustible, mas no el tipo de especie. En tanto, existen varias clasificaciones de combustibles forestales. Cada una de estas lleva asociada una serie de características propias como, por ejemplo, la carga de biomasa, la composición en diferentes tamaños o las humedades promedio (Cocero *et al.*, 2004). Por medio de lo anterior, es posible estimar el peligro o el comportamiento asociado a cada tipo de combustible en caso de que sea afectado por un incendio (Rothermel, 1972). Así, al día existen programas como FARSITE (Finney, 1998) o sistemas como el *Ignition Probability* (IP) (Chuvieco *et al.*, 2004a) que permiten estimar la probabilidad de ignición, su propagación (*Rate of Spread*), entre otras variables calorimétricas. Es interesante destacar que para

el caso del IP, éste se relaciona o tiene como parámetros de entrada el contenido de humedad de los combustibles vivos, más conocido como *Live Fuel Moisture Content* ó L-FMC en adelante.

Se han creado una serie de modelos de combustibles clasificados a partir de una serie de características intrínsecas a éstos (Albini, 1976). A partir de los modelos de Albini (1976) se han generado una serie de estudios y aplicaciones. Cabe destacar entre algunas propuestas, las de Sandberg *et al.* (2001), en donde establecen que los modelos de Albini (1976) sirven como discriminación para los diversos tipos de combustibles para la planificación de la extinción de incendios o para estimar el peligro, pero que pueden resultar algo grosero cuando se quiera utilizar para predecir el comportamiento del fuego o para estimar la biomasa consumida, ya que resume en demasía las propiedades de los combustibles.

En tanto, Chuvieco *et al.* (2003b) establecen que una correcta descripción de las propiedades de los combustibles es crítica para mejorar la gestión del peligro de incendios forestales y su modelo de comportamiento, puesto que son los parámetros de entrada para el proceso de ignición y de propagación del fuego.

Así, por ejemplo, Burgan *et al.* (1998) utilizaron las imágenes del satélite NOAA con alta resolución temporal (imagen cada 12 horas) y, a su vez, una serie temporal del NDVI (*Normalized Difference Vegetation Index*) para generar mapas de vegetación en conjunto con información auxiliar y un exhaustivo trabajo de campo. Por otro lado, Keane *et al.* (2001) proponen un trabajo de campo con fotografía aérea, lo cual resultó ser muy costoso. En un estudio realizado por Salas y Chuvieco (1995), se dan a conocer las razones por las cuales se justifica y se argumenta sobre el empleo de las imágenes satelitales para la cartografía de modelos de combustibles. Así, a modo de resumen, ellos determinan lo siguiente:

- El costo de utilizar imágenes satelitales versus fotografía aérea resulta mucho más beneficioso económicamente.
- Permite ofrecer una cobertura global. Entendiendo que un satélite de observación terrestre ubicado a 800 [km] de altura, orbita a velocidades promedio de 7 [km s⁻¹], por lo que da una vuelta al mundo en no más de 100 minutos. Claramente lo anterior también depende de la capacidad del sensor u carga útil que el satélite lleve (por la capacidad para tomar cierta cantidad de imágenes, con la finalidad que se espera para su uso en el tema en cuestión).
- Dispone de información en regiones no visibles del espectro (Infrarrojo cercano, Infrarrojo medio, SWIR, térmico, microondas).
- Los datos se pueden gestionar e interpretar digitalmente, lo que permite realizar operaciones complejas, costosas o inaccesibles al análisis visual (Chuvieco *et al.*, 2002).

Lo anterior claramente se puede expandir para una serie de análisis, como podría ser el estudiado en el presente proyecto. En efecto, se podría utilizar una cámara multiespectral o hiperspectral sobre un avión para determinar los índices que se estudiarán, pero eso conlleva unos costos muy altos, siendo que imágenes satelitales como las del Landsat 8, Aqua & Terra, entre otras, son de libre acceso.

También se han utilizado los sensores NOAA–AVHRR (Burgan *et al.*, 1998), pero en menor medida, ya que cuentan con muy baja resolución espacial (1,09 [km] por píxel – NASA, 2013), la diferencia radica en que se ha utilizado para cartografiar grandes extensiones de territorio pero, como se verá luego, al tener una alta resolución temporal ha sido utilizado para detectar cambios en cuanto a estimaciones del contenido de humedad de la vegetación viva (*Live Fuel Moisture Content* – L-FMC), pero tiene la limitante, al igual que el sensor Modis abordo de los satélites Aqua y Terra de NASA, de que si bien cuentan con elevada resolución temporal, cuentan con muy baja resolución espacial, por lo que no permite discriminar entre especies, y cabe destacar que el L-FMC varía entre especies (Yebra

et al., 2013).

Otro tipo de sensores que se han utilizado son los *Radar* como, por ejemplo, el ERS 1-SAR (*European Remote-Sensing Satellite, Synthetic Aperture Radar – SAR*), que se ha utilizado para diferenciar estructuras de vegetación, pudiendo cuantificar la cantidad de biomasa. Y, si se mezcla con imágenes TM (*Thematic Mapper – Sensor abordo del Landsat 7*), se puede discriminar mejor entre los modelos de combustibles (Cocero *et al.*, 2004). Los sensores de apertura sintética (SAR), tiene como beneficio el ser sensores activos, por lo que utilizan longitudes de onda más grandes que le permiten traspasar las nubes sin problemas y, también, poder adquirir fotografías en la noche (Martínez y Scavuzzo, 2015). A su vez, dicho sensor es muy útil y ha sido ampliamente utilizado para la detección de cambios, siendo, según Martínez y Scavuzzo (2015) imbatible en dicha aplicación, donde el único problema que se presenta es la topografía, que se debe corregir con modelos digitales de elevación (*Digital Elevation Models – DEM*).

También se encuentran las imágenes híperespectrales aerotransportadas conocidas como AVIRIS (*Airborne Visible/Infrared Imaging Spectrometer*), donde la cantidad de bandas que tienen estos sensores permiten discriminar especies y distinguir entre hojarasca y suelo descubierto (Keane *et al.*, 2001). Al contar con más bandas, es posible realizar mediciones mucho más exactas, ya que los anchos de bandas son estrechos y se pueden adecuar más a algún proceso específico.

Por otro lado se encuentran los modelos biofísicos para la elaboración de cartografías de modelos de combustibles. Gates (1991) propone que las variables más relacionadas con la generación de incendios forestales son el clima, la vegetación y la topografía del sector, y afirma que la ocurrencia de un incendio está estrechamente relacionado con la productividad vegetal del lugar, las condiciones biofísicas y la influencia humana.

Hoy, por medio de la teledetección espacial es posible determinar mediante series de tiempo, por ejemplo, la configuración histórica del sector y, también, los gradientes ambientales que son los fenómenos biogeoquímicos que influyen directamente en la vegetación y en la dinámica del combustible (Cocero *et al.*, 2004).

En el Anexo E se encuentra un cuadro resumen realizado por Cocero *et al.* (2004), donde da a conocer los diversos autores, fechas, técnicas empleadas, sensores utilizados y sistemas de clasificación digital de mapas de modelos/tipos de combustibles, dicho cuadro se puede observar en la Tabla E.1.

En lo que concierne a tipos de combustibles, es importante destacar las diferencias que existen entre los combustibles vivos y muertos en cuanto a su contenido de humedad (*Live Fuel Moisture Content –L-FMC–* y *Dead Fuel Moisture Content –D-FMC–*, respectivamente), ya que cada uno aporta de forma distinta al proceso de ignición del fuego y, por ende, se calculan de forma distinta. Así, los combustibles muertos (D-FMC) son calculados empíricamente con variables meteorológicas, diámetro del material y composición bioquímica en muchos modelos de peligro de incendios (Danson y Bowyer, 2004; Viney, 1991). El contenido de humedad de los combustibles vivos (L-FMC) es mucho más difícil de estimar por medio de información meteorológica que el contenido de humedad de los combustibles muertos (D-FMC), ya que las plantas tienen una variedad de estrategias de adaptación a la humedad y pueden recurrir a esta en los suelos (Viegas *et al.*, 2001). Así, los L-FMC son influenciados por el contenido de humedad de los suelos y, por ende, son temporal y espacialmente más variables que los combustibles muertos (Danson y Bowyer, 2004).

McAllister *et al.* (2012) establecen que los incendios más impredecibles e incontrolables son aquellos que ocurren en el dosel de los combustibles vivos (incendios de corona), donde también dan a conocer lo poco que se conoce sobre el proceso de combustión de los mismos. A su vez, se destaca que la vegetación viva puede contener hasta un 250 % de contenido de humedad, en donde los combustibles

que poseen bajo un 70 % de humedad (L-FMC) son aquellos que acarrear los incendios más vigorosos. Una hipótesis del estudio realizado por [McAllister et al. \(2012\)](#) respecto a lo anterior es que cuando los combustibles vivos son sometidos a altas temperaturas, es posible que el agua no se libere fácilmente por evaporación a través de los estomas de la vegetación, sino que se libera más en forma explosiva a medida que las paredes celulares de las plantas estallan debido a las altas temperaturas.

[Yebra et al. \(2013\)](#) establecen que la información satelital provee la oportunidad de estimar el L-FMC sobre largas áreas con buenas resoluciones espaciales y temporales, pero que dicha data requiere de calibración y validación. Algunos ejemplos serían los estudios realizados por [Chuvieco et al. \(2002\)](#); [Peterson et al. \(2008\)](#); [Wang et al. \(2013\)](#) y [Yebra et al. \(2008b\)](#).

Dentro de la importancia de conocer y estimar el L-FMC para la gestión del riesgo de incendios forestales, [Yebra et al. \(2013\)](#) dan a conocer que mayores niveles en el contenido de humedad de los combustibles vivos (L-FMC), debiesen aumentar el tiempo de ignición (tiempo en que la muestra logra la ignición) y disminuir la probabilidad de ignición. En afinidad con lo anterior, [Xanthopoulos y Wakimoto \(1993\)](#) llevaron a cabo un experimento en donde se determinó que el L-FMC es uno de los principales determinantes del tiempo de ignición, una variable relevante asociada al proceso de ignición.

Por otro lado, autores como [Schoenberg et al. \(2003\)](#) han estudiado incendios históricos y han demostrado relaciones entre el contenido de humedad en los combustibles vivos y la ocurrencia y tamaño de los mismos. Otro ejemplo es el estudio realizado por [Dennison et al. \(2008\)](#), en donde se investigó para algunas especies el LFMC y el tamaño y ocurrencia del fuego en *Santa Monica Mountains of California*, EE.UU, en donde encontraron que mientras incendios pequeños tomaban un amplio rango de LFMC (entre 59 a 139 %), los incendios grandes (con superficie mayor a 10 km²) solo ocurrieron cuando el LFMC era menor o igual a 77 %, resultados que convergen bastante con los encontrados por [McAllister et al. \(2012\)](#).

De esta forma, cabe destacar que existe suficiente evidencia científica que demuestra los efectos del LFMC sobre la ocurrencia de incendios y el alcance de su impacto, por lo que a continuación se entrará en detalle sobre la biomasa como combustible de incendios forestales, específicamente en los combustibles vivos y en algunas definiciones que son necesarias para el análisis experimental como lo son para ejecutar PROSPECT, con el fin de entender las variables que utiliza tanto el modelo de transferencia radiativa, como las que se analizarán en el proyecto.

2.3.1 Leaf Area Index

El *Leaf Area Index* ó Índice de área foliar, desde ahora LAI, es un parámetro adimensional que es utilizado para describir los procesos de los ecosistemas (físicos y biológicos) de bosques (a nivel de dosel – *Canopy*) y que puede ser obtenido mediante teledetección satelital ([Liu et al., 2014](#); [Myneni et al., 2002](#); [Rautiainen, 2005](#); [Zhang et al., 2014b](#)) y por distintos métodos en tierra ([Bréda, 2003](#); [Gower et al., 1999](#); [Jonckheere et al., 2004](#); [Zheng y Moskal, 2009](#)). El LAI fue definido por [Watson \(1947\)](#) como el total de un lado (*one-sided*) del área de una hoja (A_{lf}) por unidad de área de la superficie (A_g) (*ground surface area*). Así:

$$LAI = \frac{A_{lf}}{A_g} \quad (2.18)$$

El LAI es una variable importante para poder detectar el contenido de humedad en la vegetación por unidad de área a nivel de dosel (*Canopy Water Content*, CWC, el cual también se llamará más adelante, por fines prácticos, EWT_{Canopy} – [Al-Moustafa et al., 2012](#); [Yebra et al., 2013](#)). A su vez, este índice es uno de los principales factores de confusión para la estimación del contenido de humedad de

los combustibles vivos como porcentaje de la biomasa (*Live Fuel Moisture Content* – L-FMC) a nivel de dosel, debido a sus variaciones espaciales y temporales (Bowyer y Danson, 2004). Pero cuando sus variaciones son bajas (lento crecimiento de la vegetación a nivel de dosel – *canopy*) se pueden esperar fuertes correlaciones entre la reflectancia espectral del dosel y el L-FMC (Al-Moustafa *et al.*, 2012; Danson y Bowyer, 2004).

Ahora bien, en la literatura el LAI tiene diversas definiciones y métodos de estimación, lo que hace más complejo la comparación entre trabajos. Es debido a lo anterior que Zheng y Moskal (2009) realizaron una compilación de definiciones del LAI, explicando diversas teorías y discuten sobre diversos métodos (también: Bréda, 2003; Jonckheere *et al.*, 2004) de estimaciones del LAI y sensores de teledetección.

En los primeros estudios sobre el LAI, debido a la compleja distribución del follaje dentro del dosel, se desarrolló un modelo que modifica la Ley de Beer's de la extinción de la luz. Para entender el dosel, es necesario abarcar la siguiente definición: La estructura del dosel se define como la cantidad y organización espacial, sobre el suelo, de plantas, lo que incluye hojas, tallos, ramas, flores y frutas, que afectan a factores ambientales como la temperatura del aire, la temperatura de la hoja, la humedad atmosférica, la evaporación del suelo bajo el dosel, el almacenamiento de calor en el suelo, la humedad de las hojas, y otros (Norman y Campbell, 1989; Zheng y Moskal, 2009). A su vez, cabe destacar que mientras más denso sea el dosel, mayor es la absorción y reflectancia de la radiación solar y menos energía es transmitida al suelo (Zheng y Moskal, 2009).

De esta forma, existen dos métodos para estimar el LAI, los métodos directos e indirectos (Jonckheere *et al.*, 2004; Zheng y Moskal, 2009).

Métodos directos

Los métodos directos son los más certeros, pero tienen la desventaja de requerir bastante tiempo y, por ende, la implementación para la estimación a una mayor escala es prácticamente inviable (Jonckheere *et al.*, 2004). Como se dijo con anterioridad, existen múltiples definiciones del LAI (Zheng y Moskal, 2009), por ende, Jonckheere *et al.* (2004) establecen que los problemas de precisión para la estimación resultan a partir de dichas definiciones. Por un lado, es importante destacar que la determinación del LAI por método directo no es realmente compatible con el monitoreo tanto espacial como temporal a largo plazo. Sin embargo, la necesidad de la validación de los métodos indirectos permanece, por lo que las técnicas directas de estimación pueden ser consideradas relevantes como método de calibración (Jonckheere *et al.*, 2004). Por otro lado, cabe destacar que Jonckheere *et al.* (2004) establecen dos metodologías para la estimación directa del LAI, que son la recolección de hojas y las técnicas de determinación del área de las mismas, siendo una tarea bastante laboriosa.

Métodos indirectos

Los métodos indirectos, en cual el área de la hoja es inferida a través de observaciones de otras variables, son generalmente más rápidos, posibles de automatizar, y, por ende, permiten estimar el LAI para extensas áreas (Jonckheere *et al.*, 2004). Dentro de estos métodos se encuentran los métodos de contacto indirecto para medir el LAI y los métodos indirectos sin contacto para medir el LAI. De estos, es relevante recalcar que existen métodos indirectos bastante utilizados como lo son los ceptómetros, que es un instrumento capaz de medir la fracción del sol o la cantidad de radiación activa fotosintética (PAR – *Photosynthetic Active Radiation*) a partir de la sonda del instrumento colocado bajo el dosel y en un terreno abierto (Jonckheere *et al.*, 2004). Un ejemplo de estos son el Accupar-80 (Decagon Devices Inc., Pullman, WA, USA), pero se determina que no son aptos para bosques coníferos. Por otro lado, se encuentran instrumentos para la medición indirecta del LAI como el LAI-2000 (Licor Inc., Nebraska, USA) que es portable y no requiere información adicional y procesamiento, es capaz

de entregar estimaciones inmediatas del LAI midiendo la radiación difusa a partir de un sensor de ojo de pez que permite captar la luz en 5 distintos grados (técnica similar se puede aplicar con la fotografía hemisférica en conjunto con programas de procesamiento de éstas para determinar el LAI). Existen una serie de otros instrumentos, como lo son el TRAC y DEMON, pero ahondar en estos se aleja del foco del presente proyecto.

2.3.1.1 LAI a partir de información satelital

La premisa para obtener el LAI basado en información espectral de sensores remotos se basa en las características únicas de respuesta espectral de las hojas verdes comparado con otros materiales en la superficie del suelo (Zheng y Moskal, 2009).

En la literatura se han encontrado diversas metodologías para estimar el LAI por medio de información satelital. Chen (1996) propuso un índice llamado *modified simple ratio* (MSR) con el fin de estimar el LAI por medio de imágenes del sensor TM (*Thematic Mapper*) a bordo del satélite Landsat 5. El índice MSR se propone a partir del índice *simple ratio* (SR); éstos se definen como:

$$SR = \frac{\rho_{NIR}}{\rho_{RED}} \quad (2.19)$$

$$MSR = \frac{\frac{\rho_{NIR}}{\rho_{RED}} - 1}{\sqrt{\frac{\rho_{NIR}}{\rho_{RED}} + 1}} = \frac{SR - 1}{\sqrt{SR + 1}} \quad (2.20)$$

Donde ρ_{NIR} es la reflectancia de la banda del infrarrojo cercano y ρ_{RED} es la reflectancia de la banda roja. El estudio realizado por Chen (1996) consistió en comparar diversos índices espectrales de vegetación con el fin de realizar regresiones para estimar el LAI. Así, los mejores resultados se obtuvieron con el índice SR, a partir del siguiente modelo de regresión lineal:

$$LAI = a + b \cdot VI \quad (2.21)$$

Donde VI es el *Vegetation Index* (los que utilizaron en su estudio, incluyendo SR), LAI es el *Leaf Area Index* y a, b son los coeficientes de regresión.

Brown *et al.* (2000) modificaron el índice *simple ratio* (SR) debido a los resultados de Chen (1996) con el fin de establecer un nuevo índice: *Reduced Simple Ratio* (RSR) que incluye la banda SWIR (*short wave infrared* – Infrarrojo de onda corta) en el análisis con la finalidad de obtener mejores correlaciones entre las variables. Así, éste nuevo índice se calcula como:

$$RSR = SR \cdot \left[1 - \frac{SWIR - SWIR_{\min}}{SWIR_{\max} - SWIR_{\min}} \right] \quad (2.22)$$

Donde RSR es el *Reduced Simple Ratio*, SR es el *Simple Ratio*, SWIR es la reflectancia en determinado pixel bajo análisis de la banda (*Short-wave Infrared*), $SWIR_{\min}$ es la reflectancia del SWIR de un dosel completamente cerrado y $SWIR_{\max}$ es la reflectancia del SWIR para un dosel abierto (que se ve la superficie). Con éste nuevo índice, los coeficientes de correlación (R^2) aumentaron una media de 22 % para las muestras que analizaron con RSR versus las muestras con SR, obteniendo, por ejemplo, un $R^2 = 0,703$ para *Pinus banksiana* (*Jack Pine*) con el índice RSR versus un $R^2 = 0,536$ para la

misma muestra con el índice SR (un 30 % más) (Brown *et al.*, 2000).

El objetivo de obtener el LAI por medio de información satelital es claro, generar mapas con dicho factor a gran escala para determinar tanto parámetros biofísicos como bioquímicos de la vegetación (Houborg *et al.* (2015)). Así, la misión de realizar mapas de LAI ha sido un objetivo llevado a cabo por la comunidad científica. Se encuentran diversos estudios enfocados en el uso de distintos satélites. Por ejemplo, Chen y Cihlar (1996); Ganguly *et al.* (2012); Houborg *et al.* (2015); Zhang *et al.* (2014b), entre otros, se han dedicado a realizar diversos estudios que incluyen la estimación del parámetro LAI por medio de imágenes Landsat. Houborg *et al.* (2015) se enfocaron en la obtención del contenido de clorofila y el LAI por medio de información satelital del Landsat 7 (sensor ETM+) utilizando un modelo de un método regularizado de la reflectancia del dosel. Chen y Cihlar (1996) utilizaron índices de vegetación (SR y NDVI) del sensor TM a bordo del satélite Landsat 5 para estimar el LAI en bosques coníferos. Ganguly *et al.* (2012) desarrollaron un algoritmo físico para obtener el LAI a 30 metros de resolución espacial (tamaño del píxel del Landsat 7) a partir de información de la reflectancia de la superficie por medio del satélite Landsat 7 e información del sensor MODIS a bordo de los satélites Aqua y Terra.

En base a lo anterior, también existe un amplio uso de información del sensor MODIS (*MODerate-resolution Imaging Spectroradiometer*), a bordo de los satélites Aqua y Terra, para realizar mapas del LAI. Por ejemplo, Liu *et al.* (2014); Myneni *et al.* (2002); Yang *et al.* (2006) han enfocado su estudio al empleo de imágenes MODIS para determinar el LAI. En este punto es importante destacar que Myneni *et al.* (2002) realizaron un algoritmo físico de modelos de transferencia radiativa para doseles de vegetación para obtener el LAI. Así, el resultado es el producto MOD15A2 del sensor MODIS que se puede encontrar en la página web de los productos de dicho sensor (LPDAAC, 2014). De esta forma, el producto MOD15A2H (del satélite Terra) ofrece un total de 6 capas que incluyen, entre otros, el LAI y FPAR (*Fraction of Photosynthetically Active Radiation* – Fracción fotosintética de la radiación activa). El producto MOD15A2H se compone cada 8 días, y está disponible (libre acceso) desde el año 2000 en adelante. Así, el gran beneficio que tiene el empleo de dichas imágenes es su alta resolución temporal (productos cada 8 días), pero carece de resolución espacial (píxeles de 1km × 1km) para un tamaño de imagen de 2.330 km (swath) (LPDAAC, 2014; NASA, 2015c). De esta forma, han nacido estudios (Gao *et al.*, 2012) con el fin de realizar un método para obtener el LAI desde imágenes Landsat (resolución espacial: 30m × 30m; resolución temporal: cada 16 días; ancho de la imagen: (Swath) 185 km; NASA, 2011) utilizando los productos de MODIS (MOD15A2H – LAI) como referencia (similar al caso de Ganguly *et al.*, 2012). Lo anterior se debe a que la precisión requerida para el LAI, en términos de RMSE (*Root Mean Square Error* – Error Cuadrático Medio), es aproximadamente 0,5 unidades según el Sistema Global de Observación Climática (*Global Climate Observation System*) (Fernandes *et al.*, 2014; Ganguly *et al.*, 2012), mientras que el RMSE para el producto de MODIS (MOD15A2H) es de 12 % (RMSE = 0.66) (Yang *et al.*, 2006).

Existen, a su vez, estudios con otros sensores, como el sensor MISR (también de los satélites Aqua y Terra) (Pinty *et al.*, 2011), el sensor VEGETATION (a bordo del satélite SPOT- 4,5) (Baret *et al.*, 2007, 2013), entre otros.

2.3.2 Pigmentos de la vegetación

Parámetros bioquímicos como el contenido de clorofila de la vegetación, pueden proveer una percepción valiosa para el desempeño fisiológico de las plantas (Gitelson *et al.*, 2003; Zhang *et al.*, 2011b). La clorofila es el principal pigmento fotosintético en la vegetación y se caracteriza por absorber gran parte de la radiación electromagnética en las regiones del rojo y azul, y la refleja en la región del verde, color percibido por el ojo humano (Lichtenthaler, 1987). Por otro lado, los carotenoides son el segundo mayor grupo de pigmentos en las plantas, compuestos de carotenos y xantófilas. Los carotenoides pueden absorber la radiación incidente y contribuir con energía para la fotosíntesis (Bartley y Scolnik,

1995). En conjunto con la antocianina (pigmento hidrosoluble que se halla en las vacuolas de las células vegetales y que otorgan el color rojo, púrpura o azul a las hojas, flores y frutos), los carotenoides proveen protección para el exceso de luz, por ejemplo, en el desarrollo de la hoja o por estrés abiótico (Close y Beadle, 2003; Gould *et al.*, 2008).

Existen varios tipos de clorofila, sin embargo las más relevantes son la Clorofila “a” y “b”, siendo la primera la encargada del proceso de absorción de la luz y la segunda un pigmento accesorio (Lichtenthaler, 1987).

La obtención de el contenido total de clorofila (C_{a+b}) y de carotenoides (C_{car}) tiene una serie de aplicaciones en la agricultura, ecología y en las ciencias de la tierra (Féret *et al.*, 2011). La cantidad de clorofila a nivel de hoja es posible de estimar a través de experimentos en laboratorios. Pigmentos como la clorofila y carotenoides son compuestos liposolubles que pueden ser extraídos de los tejidos de plantas vivas por solventes orgánicos como la acetona, metanol o etanol (Lichtenthaler, 1987). La metodología más ampliamente utilizada en laboratorio para medir la cantidad de clorofila consiste en extraer los cloroplastos aislados al 100 % de una solución acuosa de acetona para garantizar una extracción completa de estos (Lichtenthaler, 1987). Ahora bien, este proceso es de tipo destructivo, ya que se requiere destruir la vegetación con el fin de obtener su cantidad de clorofila. Por otro lado, existen metodologías para estimar la cantidad de clorofila y carotenoides a partir de información espectral. A través de medidas del espectro reflectivo de la vegetación es posible gestionar de manera rápida y no destructiva el contenido de clorofila en las hojas (Féret *et al.*, 2011; Gitelson *et al.*, 2003; le Maire *et al.*, 2008). Existen una serie de índices espectrales que se han desarrollado con el fin de poder estimar, a partir de diversos tipos de relaciones estadísticas, la cantidad de clorofila a nivel de las hojas. Por ejemplo, en el estudio realizado por Gitelson *et al.* (2003), donde se propuso un índice para estimar la clorofila y carotenoides, los errores de predicción (RMSE – *Root Mean Square Error*) no superaron los 50 [$\mu\text{mol m}^{-2}$] en las hojas cuyo total de clorofila se encontraba entre rangos de 1 a 830 [$\mu\text{mol m}^{-2}$]. El índice anterior, que no cuenta con nombre definido por el autor, se le llamó Índice de Gitelson, y se puede apreciar en la Tabla 2.4 de la sección Índices espectrales (Sección 2.2.4).

Así como el Índice de Gitelson, existen varios índices para estimar el contenido de clorofila u carotenoides. Por ejemplo, Main *et al.* (2011) estudiaron 73 índices espectrales para estimar la cantidad de clorofila para 4 especies distintas de vegetación y realizan un *ranking* de los índices en base a sus errores cuadráticos medios (RMSE), en donde se puede ubicar el índice de Gitelson en lugar 16 con un RMSE de 64,41 [mg m^{-2}] como valor medio para las especies bajo análisis. le Maire *et al.* (2008) proponen índices hiperespectrales para calcular el LAI (*Leaf Area Index*), la cantidad de clorofila y el LMA (*Leaf Mass per Area*) utilizando espectrometría de campo e información satelital del sensor Hyperion abordo del satélite EO-1 de NASA. Así también existen otros estudios como el realizado por Mishra y Mishra (2012), donde se propone un índice llamado NDCI (*Normalized Difference Chlorophyll Index*) para predecir la concentración de clorofila *a* (C_a) a partir de información satelital.

2.3.3 Equivalent Water Thickness

El *Equivalent Water Thickness*, desde ahora EWT, se define como la cantidad de agua por unidad de área de la hoja que asume un hipotético grosor de una sola capa de agua promediada a lo largo de toda el área de ésta (Danson *et al.*, 1992). Así, se tiene que:

$$\text{EWT} = \frac{W_f - W_d}{A} \quad (2.23)$$

Donde W_f es el peso fresco (*Fresh Weight*), W_d es el peso seco (*Dry Weight*) y A el área de la hoja (Danson *et al.*, 1992). El peso fresco (W_f) se determina pesando la muestra (fresca) en una balanza,

en tanto, para el cálculo del peso seco es necesario secar la muestra en un horno para luego pesarla y obtener su peso seco. Aquí nacen una serie de criterios para la recolección de la muestra y para el tiempo que ésta debe permanecer en el horno y a qué temperatura (ver la [Sección 2.3.8](#) para más detalles).

El EWT, en conjunto con otros índices como el LMA (*Leaf Mass per Area*, ver [Sección 2.3.4.1](#)), es una variable crítica en el estudio de ecología de las plantas, específicamente en materia de gestión del riesgo de incendios forestales, análisis del estrés de la vegetación y el intercambio neto del contenido de carbono con el ecosistema ([Féret et al., 2011](#)).

El contenido de humedad a nivel de hoja por unidad de área, medido en función del EWT, se conoce como *Leaf water content* (desde ahora LWC). Dicha variable se ha utilizado para estimar el contenido de humedad a nivel del dosel, *Canopy water content* – CWC, si se multiplica por el factor biofísico del LAI (ver [Ecuación 2.24](#); [Hunt Jr et al., 2013b](#)).

$$CWC = LWC \cdot LAI \quad (2.24)$$

De esta forma, es importante destacar que el CWC es equivalente al EWT a nivel del dosel (*Canopy Equivalent Water Thickness*, EWT_{Canopy}), y que el LWC es equivalente al EWT a nivel de hoja (*Leaf Equivalent Water Thickness*, EWT_{Leaf}), ver [Ecuación 2.25](#).

$$EWT_{Canopy} = EWT_{Leaf} \cdot LAI \quad (2.25)$$

En la parte experimental del estudio realizado por [Ceccato et al. \(2001\)](#), se deduce que las variaciones de la reflectancia en el SWIR¹ solo proveen información de agua por unidad de área, es decir: EWT, y no del porcentaje de agua presente en la biomasa (FMC), como se verá más adelante. De esta forma, es importante destacar que el EWT a nivel de hoja (EWT_{Leaf}) se puede estimar por medio de información satelital, y que para esto son necesarias las bandas del SWIR y NIR² ([Ceccato et al., 2002b](#); [Yebra et al., 2013](#)).

A nivel de dosel, autores como [Downing et al. \(1993\)](#) y [Hunt Jr y Rock \(1989\)](#) propusieron relaciones entre el contenido de humedad de la vegetación e índices espectrales (ver [Sección 2.2.4](#) para su revisión). A su vez, conociendo el EWT_{Leaf} se podría utilizar una estimación del LAI para evaluar el contenido de humedad a nivel del dosel por unidad de área (EWT_{Canopy} ; [Hunt Jr et al., 2013b](#)), como se dijo anteriormente.

[Mobasheri y Fatemi \(2013\)](#) analizaron el EWT como un parámetro para estimar el contenido de agua a nivel de la hoja en el rango comprendido entre los 400 – 2.500 nm del espectro de reflexión de la vegetación. Ellos relacionaron los valores del EWT con 3 ecuaciones (ver ecuaciones [2.26](#), [2.27](#) y [2.28](#)) para establecer distintos métodos con sus respectivas correlaciones entre reflectancias, determinadas longitudes de onda y valores del EWT. A su vez, una parte de su experimento fue relacionar el EWT con tan solo una reflectancia a determinada longitud de onda (λ), en donde la menor correlación obtenida fue a los 1.318 nm ($R^2 = 0,00001$) y la mayor se obtuvo a los 1.400 nm ($R^2 = 0,63$).

¹Shortwave Infrared ó Infrarrojo de onda corta: 1.200 – 2.500 nm.

²Near Infrared ó Infrarrojo cercano: 700 – 1.200 nm.

$$EWT = a \cdot (R_{\lambda_i} - R_{\lambda_j}) + b \quad i, j = 1, 2, \dots, i \neq j \quad (2.26)$$

$$EWT = a \cdot \left(\frac{R_{\lambda_i}}{R_{\lambda_j}} \right) + b \quad (2.27)$$

$$EWT = a \cdot \left(\frac{R_{\lambda_i} - R_{\lambda_j}}{R_{\lambda_i} + R_{\lambda_j}} \right) + b \quad (2.28)$$

En donde $R_{\lambda_i}, R_{\lambda_j}$ son las reflectancias a una longitud de onda λ_i y λ_j (respectivamente), y a, b son los coeficientes de regresión. Los mejores resultados se obtuvieron con la Ecuación 2.28 ($R^2 = 0,95$), en donde los valores para R_{λ_i} y R_{λ_j} fueron 1.152 nm y 1.128 nm, respectivamente.

Por otro lado, cabe destacar que también hubieron buenos resultados con $R^2 \geq 0,9$ para el caso de la Ecuación 2.27, entre los rangos 1.050 – 1.870 nm y 741 – 1.376 nm para R_{λ_i} y R_{λ_j} , respectivamente. Por último, cabe destacar que es para la ecuación anterior (2.27) que se encontró el rango más amplio de longitudes de onda en donde los coeficientes de correlación fueron mayor a 0,9 ($R^2 \geq 0,9$).

En el estudio realizado por Hunt Jr et al. (2011), se encontraron significantes relaciones lineales entre el LWC (EWT_{Leaf}) y el CWC (EWT_{Canopy}) en las siguientes longitudes de onda: 970, 1.240 y 1.650 nm.

En el estudio realizado por Liu et al. (2015), se encontró que las absorciones de agua a nivel de hoja (*Leaf Level*) ocurren en las regiones del SWIR y centradas en los 1.450, 1.510 y 1.860 nm. Y, a su vez, una débil absorción de agua centrada en las bandas de los 970 y los 1.200 nm. También, dentro de los resultados obtenidos por Liu et al. (2015), se determina que la absorción de agua al rededor de las bandas 1.450 y 1.860 nm se ven fuertemente influenciadas por vapor de agua en la atmósfera y que por lo tanto, concluyen que no pueden ser utilizadas ni por información de Aviris (*Airborne Visible Infrared Imaging Spectrometer*) o satelital.

En la literatura más antigua (Knipling, 1970; Tucker, 1980) se encontró que las bandas de absorción de agua se centran en los 970, 1.200, 1.450, 1.950 y 2.500 nm.

Si bien existen diferencias en las longitudes de absorción de agua, la totalidad de los estudios leídos convergen en que es en la región del SWIR donde ocurre dicha absorción.

Existen bases de datos bastante amplias que se han utilizado para generar modelos de regresiones como los generados por Mobasheri y Fatemi (2013) en las ecuaciones 2.26, 2.27 y 2.28. Un caso particular es la base de datos llamada *Leaf Optical Properties Experiment 93* (LOPEX93), un experimento que fue organizado por la *Joint Research Centre (Istituto Superiore per la Protezione e la Ricerca Ambientale, Italia)* en el ISPRA durante el verano de 1993 (Hosgood et al., 1994). Dicha base de datos contiene muestras de 45 especies diferentes, donde se experimentó con 331 hojas, cuenta con valores como la cantidad de clorofila (a, b y a+b), carotenoides, EWT, LMA (*Leaf mass per area*), entre otras Hosgood et al. (1994). LOPEX93 ha sido ampliamente utilizada por investigadores para realizar diversos tipos de análisis (Ceccato et al., 2002a,b; Jacquemoud et al., 1996; Mobasheri y Fatemi, 2013; Shen et al., 2005). Algunos de estos análisis son, por ejemplo, modelos de transferencia radiativa (*Radiative Transfer Model*, RTM) como PROSPECT, un modelo óptico de las propiedades espectrales de las hojas (Jacquemoud y Baret, 1990). En la Sección 2.2.3.3.1 se puede apreciar en profundidad sobre las bases de datos, mientras que en la Sección 2.2.3.3 se puede apreciar en profundidad sobre los modelos de transferencia radiativa.

En cuanto a la estimación del EWT, muchos autores han determinado que el *leaf* y *canopy water content*, medido en términos de EWT_{Leaf} y EWT_{Canopy} , se pueden estimar de información satelital por

medio de índices de vegetación (Ceccato *et al.*, 2002a; Danson y Bowyer, 2004; Datt, 1999a; Dawson *et al.*, 1999; Féret *et al.*, 2011; Gao, 1996; Goetz *et al.*, 1985; Jacquemoud *et al.*, 1995; Ustin *et al.*, 1998; Yebra *et al.*, 2013; Zarco-Tejada *et al.*, 2003).

Shen *et al.* (2005) utilizaron la base de datos LOPEX93 (Hosgood *et al.*, 1994) para estimar el contenido de agua en modelos que se establecieron tanto a nivel de hoja como a nivel de dosel mediante índices espectrales. En sus resultados, el NDII (*Normalized Difference Infrared Index*) $(R_{825} - R_{1650}) / (R_{825} + R_{1650})$ (Hardisky *et al.*, 1983) obtuvo un coeficiente de correlación de 0,8944 ($R^2 = 0,8944$; ver la Sección 2.2.4 para más información del NDII). En cuanto a los resultados de Shen *et al.* (2005), se establece que el NDII, es un índice apropiado para estimar el EWT a nivel de hoja (EWT_{Leaf}). Cabe destacar que Yilmaz *et al.* (2008a,b) llegaron a resultados similares.

En el estudio realizado por Danson y Bowyer (2004), las correlaciones más fuertes entre índices espectrales y el EWT fueron con el NDWI (*Normalized Difference Water Index* – Gao, 1996), MSI (*Moisture Stress Index* – Hunt Jr y Rock, 1989) y GVMi (*Global Vegetation Moisture Index* – Ceccato *et al.*, 2002a,b).

Uno de los resultados que obtuvieron Danson y Bowyer (2004) fue que los índices que mejor se correlacionaron con el EWT fueron aquellos que empleaban data en el NIR (donde la absorción de agua es débil) y en el SWIR (donde la absorción de agua es fuerte, como se dijo anteriormente). Así, establecen que gracias a dichos niveles de certeza, es posible estimar el EWT utilizando mediciones de reflectancia espectral en hojas individuales ya sea en laboratorio o en terreno con instrumentos apropiados.

Es posible concluir, entonces, que en base a todos los estudios analizados, el *Equivalent Water Thickness* ó EWT es posible calcularlo ya sea por medio de análisis de laboratorio, o bien estimarlo por medio de información satelital (índices espectrales), con correlaciones elevadas para ambos casos, como se vio anteriormente. A su vez, es importante destacar que el EWT es utilizado ampliamente para medir el contenido de humedad en estudios de teledetección satelital, y que es, a la fecha, el más común. Esto es debido a que la absorción de agua de la radiación entrante está directamente relacionada con la profundidad de la capa de agua, particularmente en las bandas del NIR y SWIR (Jacquemoud *et al.*, 1996; Yebra *et al.*, 2013), como ya se ha dicho anteriormente.

Es fundamental el destacar que si bien el EWT es el parámetro más utilizado para determinar la cantidad de agua de la vegetación por medio de información satelital, es el porcentaje de agua contenido en la biomasa ó *Fuel Moisture content* – FMC, el que determina, en el caso de los combustibles vivos, el comportamiento del fuego, su propagación (*Rate of Spread*– ROS) y la probabilidad de ignición (Chuvieco *et al.*, 2004a; Danson y Bowyer, 2004; Riaño *et al.*, 2005; Rothermel, 1972), como se verá más adelante en la Sección 2.3.5. De hecho, Bowyer y Danson (2004) determinan que es más probable obtener estimaciones del EWT que del FMC con información satelital.

2.3.4 Dry Matter Content

El contenido de materia seca (del inglés: *Dry Matter Content*), desde ahora DMC, es el parámetro que une el EWT con el FMC, y que describe la expresión aérea de la celulosa, lignina y otros componentes de las plantas que permanecen luego de secarse (Yebra *et al.*, 2013). De esta forma, si éste parámetro es calculado o estimado con certeza, es posible estimar el contenido de humedad de los combustibles vivos como porcentaje de agua contenido en la biomasa (FMC) (Riaño *et al.*, 2005).

Experimentalmente, la determinación de este parámetro se realiza con el secado de las hojas (muestras) en hornos especiales, donde se determina una cierta temperatura y tiempo de secado. Luego de secar las muestras, se procede a pesarlas en una balanza, en donde si dicho peso se divide por el área de la hoja, se tiene el valor del DMC (Desbois *et al.*, 1997a).

Riaño *et al.* (2005) estimaron el DMC y el EWT por inversión de un modelo de transferencia radiativa para las propiedades ópticas de las hojas (PROSPECT – ver Sección 2.2.3.3 para más detalles sobre modelos de transferencia radiativa), en donde la finalidad fue poder estimar el FMC. Así, es posible determinar que la relación existente entre estos tres términos es la siguiente:

$$\text{FMC} = \frac{\text{EWT}}{\text{DMC}} \cdot 100 \% \quad (2.29)$$

Luego, para entender las unidades de medida, se tiene:

$$\text{FMC} = \frac{\frac{W_f - W_d}{A}}{\frac{W_d}{A}} = \frac{W_f - W_d}{W_d} \cdot 100 \% \quad (2.30)$$

Donde W_f es la masa fresca de la muestra (*fresh leaf weight* [$g \text{ cm}^{-2}$]), W_d la masa seca (*dry leaf weight*, [$g \text{ cm}^{-2}$]) y A el área de la hoja [cm^2]. Es así, entonces, como el DMC se define como la cantidad de masa seca por unidad de área de la hoja.

Riaño *et al.* (2005) invirtieron el modelo de transferencia radiativa PROSPECT con el fin de poder estimar el FMC de la base de datos de LOPEX93 (Hosgood *et al.*, 1994). El método de inversión utilizado fue el llamado *PROSPECT-Lillesaeter* (Lillesaeter, 1982), que permite simular el EWT y DMC en base al estudio de laboratorio de LOPEX93. La forma de realizar dicha inversión es por medio de la siguiente expresión:

$$\rho_c = \frac{\rho_l}{1 - \tau_l^2} \quad (2.31)$$

En donde ρ_c equivale a la reflectancia del dosel (canopy), ρ_l equivale a la reflectancia de la hoja y τ_l equivale a la transmisividad de la hoja.

De los resultados obtenidos por Riaño *et al.* (2005), se da a conocer que los valores del DMC cuando las muestras estaban frescas eran bastante malos o sin sentido alguno ($R^2 = 0,38$), lo que resultaba en un FMC, a su vez, bastante pobre ($R^2 = 0,33$) aún cuando el EWT tenía buenos resultados ($R^2 = 0,94$). Por otro lado, cuando las muestras estaban secas, los resultados del DMC mejoraban considerablemente ($R^2 = 0,84$), debido a que no había presencia de agua. A su vez, las correlaciones del FMC aumentaron considerablemente ($R^2 = 0,89$).

Riaño *et al.* (2005) asumieron en su estudio un valor constante del DMC (a través del año), pero en las épocas de sequía se ha analizado que éste valor disminuye debido a la baja productividad de la vegetación, y se encontró que llegó a variar en hasta un -24 % (Garnier *et al.*, 2001).

Fourty y Baret (1997) explican en su estudio que el EWT es más fácil de calcular que el DMC, debido a las características específicas de absorción del agua.

El propósito de entender y estimar el DMC es para poder estimar el FMC de los combustibles vivos que es una variable que explica, como se dijo con anterioridad, la probabilidad de ignición, el comportamiento del fuego y su propagación (Burgan y Rothermel, 1984; Rothermel, 1972).

En base al contexto anterior, el análisis de los estudios que consideran los cálculos o estimaciones del DMC son, básicamente, para estimar el FMC. Así, [Riaño *et al.* \(2005\)](#) proponen evaluar el FMC con el DMC estimado de las medidas de muestras secas (que son las que proveen mejores resultados para éste) que luego se utilizará para estimar el DMC de las muestras frescas (hojas frescas), asumiendo que el DMC es dependiente de la especie. Es decir, consideraron los datos del DMC medido para las muestras secas y asumirán que es el mismo valor para las muestras frescas.

Lo anterior es un concepto bastante importante, debido a que [Ceccato *et al.* \(2001\)](#) determinó que pueden existir distintas especies con igual EWT, pero distintos FMC. Lo anterior se explica por medio de la [Ecuación 2.29](#), debido a la dependencia variable de la especie o fenología en cuanto a la densidad de materia seca de las hojas (DMC). Así lo comprobaron [Danson y Bowyer \(2004\)](#), donde utilizaron la información de la base de datos LOPEX93 para llegar a dicha conclusión.

2.3.4.1 Leaf Mass per Area

El contenido de materia seca de la vegetación puede ser expresado en términos del *Leaf Mass per Area*, desde ahora LMA, que es una variable crítica en la ecología de la vegetación, específicamente en la gestión del riesgo de incendios forestales, análisis del estado hídrico de la vegetación y del intercambio neto de carbono al ecosistema ([Féret *et al.*, 2011](#)). El LMA es el inverso del SLA (*Specific Leaf Area*), y se calcula mediante la siguiente expresión ([Asner *et al.*, 2011](#)):

$$\text{LMA} = \frac{W_d}{A} \quad (2.32)$$

Donde W_d corresponde al peso seco de la hoja y A al área de la misma. Generalmente, las unidades de medida del LMA son en gr/cm^2 . En la literatura se han abarcado por “separado” tanto el DMC como el LMA, sin embargo, corresponden al mismo valor numérico y cálculo [Garnier y Navas \(2012\)](#). En el presente estudio se seguirán llamando de forma distinta por la conveniencia que trae consigo por las fuentes de la literatura y por su uso (con el nombre de LMA) en PROSPECT.

[Asner *et al.* \(2011\)](#) utilizaron información espectral/satelital para explicar el LMA de forma no-destructiva en su experimento, donde obtuvieron resultados bastante satisfactorios (RMSE 14–15 gr/m^2 y $R^2=0,85$).

En el estudio realizado por [le Maire *et al.* \(2008\)](#), se buscó una relación por medio de información hiperespectral, un índice que pudiese explicar el LMA (así como otros parámetros). Dicho índice luego se utilizó con imágenes del sensor Hyperion abordo del satélite EO-1 de NASA, en donde se encontraron errores medios cuadráticos (RMSE) de 9,1 g m^{-2} para el LMA.

[Ali *et al.* \(2016\)](#) experimentaron con PROSPECT (modelo de transferencia radiativa – que se puede apreciar en mayor detalle en la [Sección 2.2.3.3](#)) en donde invirtieron el modelo a partir de un espectro de reflexión con el fin de obtener valores del LMA (uno de los parámetros iniciales del modelo). En sus resultados obtuvieron significantes correlaciones ($R^2=0,83$).

[Féret *et al.* \(2011\)](#) realizaron un estudio en el cual el objetivo fue encontrar relaciones espectrales con los parámetros de entrada de PROSPECT. Dentro de algunos de estos parámetros, como se dijo anteriormente, se encuentra el LMA. Se utilizaron 1.034 muestras y se les calculó su peso seco de la hoja por unidad de área, así como también se obtuvo su espectro de reflexión. En su estudio se determina una aproximación estadística a partir de valores de reflectancia en determinadas longitudes de onda para estimar el LMA en g cm^{-2} . A dicho índice creado a partir de reflectancias se le denominó

ND_{LMA} , y resultó tener un ajuste de tipo polinomial de grado 2. Dicho índice surge a partir de la siguiente expresión:

$$ND_{LMA} = \frac{\rho_{1368} - \rho_{1722}}{\rho_{1368} + \rho_{1722}} \quad (2.33)$$

En donde ρ_{1368} y ρ_{1722} corresponden a los valores de reflectancia a las longitudes de onda de 1.368 y 1.722 nm, respectivamente. Dicha diferencia normalizada entra dentro de la siguiente relación estadística para poder estimar el LMA:

$$LMA = a \cdot (ND_{LMA})^2 + b \cdot (ND_{LMA}) + c \quad (2.34)$$

En donde a , b y c son los coeficientes de la regresión polinomial. En los resultados de [Féret et al. \(2011\)](#) se pueden apreciar errores medios cuadráticos (RMSE) de 0.0021 g cm⁻² para el caso del LMA.

Cabe destacar que el LMA también ha sido estudiado por varios autores para ser estimado a partir de información satelital ([Asner et al., 2011](#); [Baret y Fourty, 1997](#); [Jacquemoud et al., 1996](#); [le Maire et al., 2008](#)).

2.3.5 Fuel Moisture Content

El *Fuel Moisture Content* (FMC) es el contenido de humedad de los combustibles como porcentaje de la biomasa. En este caso, y como se dijo anteriormente, se tratará del *Live Fuel Moisture Content* – L-FMC, o contenido de humedad en los combustibles vivos. Ya se explicó anteriormente sobre el porqué de ésta razón, pero cabe destacar que los combustibles vivos son aquellos que explican los incendios más desastrosos y los más impredecibles ([McAllister et al., 2012](#); [Yebara et al., 2013](#)).

Los cálculos del EWT y FMC son distintos, y ambos proveen medidas u información acerca del contenido de humedad presenta en la vegetación. Ahora bien, ambos se refieren a dos cantidades diferentes. [Gond et al. \(1999\)](#) midieron tanto el EWT como el FMC en su estudio, donde se concluyó que no son variables relacionadas directamente, y que son formas distintas de medir el contenido de humedad, como se dijo anteriormente. El EWT es la variación entre el peso húmedo y peso seco por unidad de área de la hoja, mientras que el FMC es el porcentaje de agua dentro de ésta. Ahora bien, estas variables se relacionan por medio de una tercera, el DMC (Ver sección [Sección 2.3.4](#)). Así, dicha relación entre las tres variables se puede observar en la ecuación (2.29).

[Danson y Bowyer \(2004\)](#) experimentaron con la data de LOPEX93 y modelaron data de PROSPECT para examinar la relación entre el FMC, EWT e índices espectrales; Encontraron fuertes relaciones entre el FMC e índices espectrales como el *Water Index* – WI, mientras que el EWT se relacionó mejor con el *Normalized Difference Water Index* – NDWI (para mayor información sobre éstos índices ver la [Tabla 2.4](#) en la sección [Índices espectrales](#)).

A su vez, [Danson y Bowyer \(2004\)](#) resaltan el hecho de que el FMC es una variable clave para el modelamiento de incendios forestales, ya que se relaciona con la probabilidad de ignición y con la propagación del mismo (*rate of spread*).

El L-FMC puede superar el 100 % de humedad, pero en el experimento realizado por [Danson y Bowyer \(2004\)](#), los resultados obtenidos para estimar el FMC en función del *Water Index* arrojaron errores muy elevados: RMSE=63,2 % para el caso del modelado por medio de PROSPECT; y RMSE=179,3 % para el caso de la utilización del *Water Index* para estimar el FMC para la data de LOPEX93. Así, [Danson y Bowyer \(2004\)](#) concluyen que estos errores disminuyen significativamente

si el porcentaje de FMC a utilizar es menor al 100 %. De esta forma, lo recalcularon solo utilizando dicha información (por ende disminuyendo considerablemente la muestra) y los resultados fueron para el modelado (PROSPECT) un RMSE=14,8 % y para el de la data de LOPEX93: RMSE=51,4 %.

Significativos estudios han mostrado que el contenido de agua en la vegetación puede ser estimado a través de información satelital, pero la mayoría de estos han examinado relaciones con el EWT a nivel de hoja o dosel (ejemplos: [Ceccato et al., 2002a](#); [Gao y Goetz, 1995](#); [Jacquemoud et al., 1995](#); [Ustin et al., 1998](#); [Zarco-Tejada et al., 2003](#)). Solo algunos estudios han examinado explícitamente la relación con el FMC, la cual es la variable rutinaria utilizada para la gestión del riesgo de incendios forestales ([Chuvieco et al., 2003a, 2002](#)).

[Bowyer y Danson \(2004\)](#) establecen que para mitigar y gestionar de mejor forma la incidencia de incendios forestales, es que los modelos del comportamiento del fuego utilizan para predecir, entre otras cosas, la probabilidad de ignición, el desarrollo y propagación del fuego (*Rate of Spread*) y la intensidad y duración del mismo ([Burgan y Rothermel, 1984](#)). Así, un proceso de entrada clave para determinar dichos parámetros es el contenido de agua en la vegetación (L-FMC), el cual tiene fuerte control en la probabilidad inicial de ignición, eficiencia de la combustión (*burning efficiency*) y el avance del fuego ([Rothermel, 1972](#)).

En cuanto al cálculo o estimación del FMC por medio de información satelital, hay muy pocos estudios que han, explícitamente, examinado relaciones entre índices espectrales y el contenido de humedad de la vegetación. Así, los métodos se han enfocados en relaciones empíricas entre dichas variables. Ahora bien, dichos resultados varían entre los estudios ([Leblon, 2001](#)). En éste ámbito, han habido algunos estudios que relacionan información espectral con la cantidad de humedad como porcentaje de la biomasa (FMC) con índices espectrales, pero que, como establecen [Yebra et al. \(2013\)](#), requieren de calibración y validación. Algunos estudios son los realizados por [Chuvieco et al. \(2002\)](#); [Peterson et al. \(2008\)](#); [Wang et al. \(2013\)](#); [Yebra et al. \(2008b\)](#).

2.3.6 Desafíos para la estimación del LFMC desde información satelital

Yebra *et al.* (2013) proponen que los desafíos para estimar la humedad de los combustibles vivos como porcentaje de la biomasa (L-FMC) a partir de información satelital son los que se encuentran en la Figura 2.30. A continuación se hará un breve resumen de los puntos más relevantes, que son factores claves para el desarrollo del presente trabajo de título.

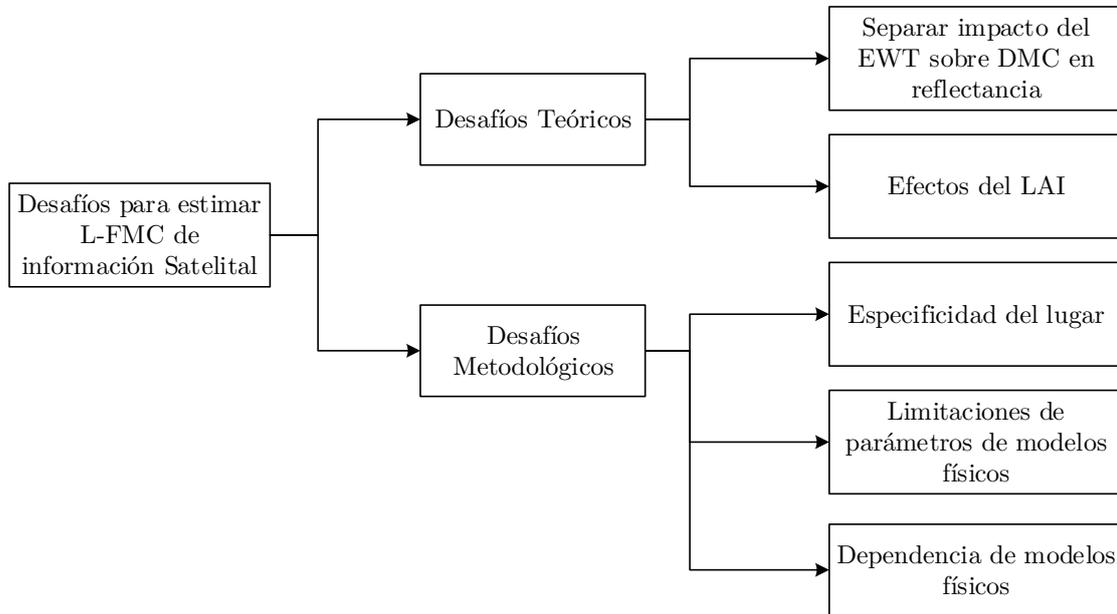


Figura 2.30: Desafíos para la estimación del L-FMC por medio de información satelital.

Fuente: Elaboración propia a partir de Yebra *et al.* (2013).

A. Desafíos Teóricos:

A.1. Separar el impacto del EWT sobre el DMC en reflectancia

- La separación del impacto del EWT sobre DMC en la reflectancia hace mención a la complejidad para el cálculo del DMC y el cómo éste se ve afectado por el EWT para su estimación. A su vez, la reflectancia también se ve afectada por otras variables como, por ejemplo, la temperatura y la retrodispersión.
- Es posible determinar el EWT por medio de información satelital (como se dijo en la Sección 2.3.3). De hecho, Trombetti *et al.* (2008) utilizaron PROSPECT y calcularon el CWC (*Canopy Water Content* – o EWT_{Canopy}) para todo Estados Unidos continental con imágenes Modis y validaron con un sensor Aviris. Pero el problema que tuvieron fue que su algoritmo para el cálculo del CWC no obtenía el DMC, que es, al final de cuentas, la variable que relaciona el EWT (a nivel de dosel i.e. EWT_{Canopy}) con el L-FMC; y, por ende, no se estimó directamente el L-FMC.
- Yebra *et al.* (2013) establecen que la obtención de un DMC más preciso permitiría la conversión del EWT_{Canopy} al LFMC, asumiendo que el factor LAI también puede ser obtenido rigurosamente. De esta forma, se tiene que la relación para la estimación de L-FMC vendría siendo la siguiente equivalencia (Hunt Jr *et al.*, 2013; Wang *et al.*, 2011b):

$$L\text{-FMC} = \frac{EWT_{\text{Leaf}} \cdot LAI}{DMC_{\text{Leaf}} \cdot LAI} = \frac{EWT_{\text{Canopy}}}{DMC_{\text{Canopy}}} \quad (2.35)$$

Así, índices espectrales que presenten sensibilidad en las absorciones al DMC podrían mejorar las estimaciones del L-FMC (Ustin *et al.*, 2012; Wang *et al.*, 2011a, 2013).

- Del punto anterior, cabe destacar que la materia seca (*Dry Matter*) exhibe varias absorciones en la reflectancia de la región del infrarojo de onda corta (SWIR – Asner, 1998; Jacquemoud *et al.*, 1995, 1996), lo que puede ser medido con sensores que cuenten con mayor resolución espectral ó, dicho de otra forma, con bandas más angostas (híperespectrales).
- Se han desarrollado índices espectrales con el fin de obtener u estimar el DMC. Algunos casos son el *Cellulose Absorption Index* (Nagler *et al.*, 2000), el *ASTER-defined Lignin-Cellulose Absorption Index* y el *Improved Shortwave-Infrared Normalized Difference Residue Index* (Serbin *et al.*, 2009). Sin embargo, estos índices no son considerados para estimar la materia seca (DMC) de combustibles vivos, sino que su enfoque es hacia los combustibles muertos.
- Ahora bien, con respecto al punto anterior, se han desarrollado dos índices basados en la diferencia espectral entre el DMC y el EWT (Romero *et al.*, 2012; Wang *et al.*, 2011a, 2013). Tal es el caso del NDMI (*Normalized Dry Matter Index*) que se basa en una fina absorción de la materia seca en los 1.722 nm, en la cual el coeficiente específico de absorción de la materia seca es mayor que el del agua (Wang *et al.*, 2011a, 2013).

El otro caso es el del NDI (*Normalized Difference Ratio* – Romero *et al.*, 2012), en donde también se estimó el DMC, pero centrado en otras longitudes de onda (2.305 nm) donde, también, los coeficientes de absorción de la materia seca son mayores que la absorción de agua líquida (ver la Tabla 2.4 para más información sobre éstos índices espectrales).

Por otro lado, mientras que los coeficientes de absorción de la materia seca pueden ser mayores que los del agua (en los 1.722 y 2.305 nm), no es certero que los índices anteriores puedan ser utilizados para medir el DMC a nivel del dosel, debido a que existe, a menudo, mayor agua líquida que materia seca en las hojas (Yebra *et al.*, 2013).

- Una de las hipótesis más relevantes de los desafíos que proponen Yebra *et al.* (2013) es la realizada por Wang *et al.* (2013), en donde plantean que un ratio con un índice espectral para la materia seca (DMC) y uno para el agua (*Water Content*) podrían estar relacionados con el L-FMC, ya que éste sería el ratio entre el EWT y el DMC. En el estudio de Wang *et al.* (2013), la relación entre los índices fue significativa, pero no lineal. El ratio NDII6 (*Normalized Difference Infrared Index*) a NDMI (*Normalized Dry Matter Index*) produjo fuertes correlaciones. Información experimental a nivel de hoja validó ésta aproximación, pero establecen que se necesitan más estudios con sensores de bandas más delgadas para realizar lo anterior a nivel de dosel. La ecuación (2.36) representa de forma más clara lo anterior.

$$L\text{-FMC}_{\text{Leaf}} = \frac{EWT_{\text{Leaf}}}{DMC_{\text{Leaf}}} = \frac{NDII}{NDMI} \quad (2.36)$$

Por lo que se puede notar que por medio de índices espectrales para tanto el contenido de humedad por unidad de área (EWT) como para el contenido de materia seca (DMC) es posible de estimar el contenido de humedad como porcentaje de la biomasa de los combustibles vivos (LFMC) a nivel de hoja.

Al utilizar un sensor que tenga mayor resolución espectral (mayor número de bandas ó bandas más cortas) es posible discriminar mejor entre los rangos de absorción en longitudes de onda, lo que generaría datos más certeros para los índices espectrales.

A.2. Efectos del LAI

- A nivel del dosel, la obtención del L-FMC por medio de información satelital necesita discriminar la influencia de la estructura de la hoja, LAI y fracción de cobertura en la reflectancia de las plantas (Ceccato *et al.*, 2002a; Zarco-Tejada *et al.*, 2003).
- Un punto importante a destacar es que, como se dijo con anterioridad, el *Canopy Water Content* o CWC es el producto entre el EWT_{Leaf} y el LAI, pero el L-FMC es independiente del LAI y puede permanecer constante mientras que el LAI varíe espacial o temporalmente (Yebra *et al.*, 2013). En otras palabras, el LAI explica variaciones en el EWT (en dónde las variaciones en éste último afectan al L-FMC) donde se enfoca la cantidad de agua por unidad de área, pero no variaciones en el contenido de humedad como porcentaje contenido dentro de la biomasa (L-FMC). Matemáticamente, la relación se puede apreciar en la ecuación (2.35), donde se aprecia que multiplicar por el factor LAI es, para el L-FMC, “multiplicar por una suerte de uno conveniente”.
- El LAI afecta significativamente al NDII (*Normalized Difference Infrared Index*), un índice sensible a la absorción de agua para valores constantes de EWT. Pero si el CWC permanece constante i.e. que el LAI no varíe, éste índice también permanecerá constante (Yebra *et al.*, 2013). Lo relevante de este punto es justamente entrelazar con información que se dijo con anterioridad, en donde Wang *et al.* (2011a) y Wang *et al.* (2013) obtuvieron buenos resultados del L-FMC estimado por medio del cociente entre los índices espectrales del NDII y NDMI a nivel de hoja.
- Otro foco relevante es uno de los puntos que Qi *et al.* (2012) dieron a conocer en su estudio, en donde establecen que la resolución espacial es parte fundamental de los problemas para estimar el L-FMC, ya que la heterogeneidad espacial de la vegetación dentro de un pixel es un problema mayor para estimar el L-FMC y para compararlo con la información obtenido de medidas de campo.

B. Desafíos Metodológicos:

B.1. Especificidad del lugar

- Debido a la especificidad de los sectores bajo análisis en cuanto a modelos estadísticos (empíricos), las relaciones empíricas no pueden ser aplicadas a escalas de nivel regional o global debido a las diferencias espaciales a nivel de características del dosel y la hoja, al fondo del suelo (*soil background*), a las características del sensor y a las condiciones de observación (Dennison *et al.*, 2005; García *et al.*, 2008; Riaño *et al.*, 2005; Yebra *et al.*, 2008a).

B.2. Limitaciones de parámetros de modelos físicos

- Los modelos de transferencia radiativa (*Radiative Transfer Models* – RTM), como PROSPECT, están basados en relaciones físicas que son independientes del sensor o de las condiciones del sector, por lo que debiesen de ser más universales que

los modelos empíricos (Yebra *et al.*, 2013). El problema de estos radica en que las parametrizaciones de estos modelos son mucho más complejas que los modelos empíricos, ya que requieren como parámetros de entrada variables como la fisiología y la estructura interna de la planta, que no siempre son fáciles de obtener o no siempre están disponibles.

B.2. Dependencia de modelos físicos

- La *performance* o desempeño de los modelos RTM tienen una fuerte dependencia en el procedimiento de inversión utilizado. Yebra (2008), en su tesis doctoral, comparó dos diferentes funciones de mérito de similaridad entre un espectro simulado y otro observado (*Relative Minimum Quadratic Distance* – $RMSE^*_{\rho}$ y *Minimum Spectral Angle* – SA), donde concluyó que el uso del SA provee medidas espectrales de similaridad más consistentes que llevaban a mejores estimaciones (menores errores) del L-FMC, con RMSE y R^2 de 14,6 % y 0,63 versus 22,43 % y 0,36, respectivamente, utilizando $RMSE^*_{\rho}$.

2.3.7 Principales problemas en la estimación del L-FMC

La presente sección es un breve resumen de lo realizado por Yebra *et al.* (2013), con el fin de destacar los puntos más relevantes para determinar los posibles problemas que puedan surgir en el presente trabajo.

2.3.7.1 Errores de estimación en el L-FMC

- Una mala estimación del L-FMC puede afectar directamente a la seguridad y los costos de los recursos (Weise *et al.*, 1998), dependiendo de la sensibilidad del modelo del comportamiento del fuego.
- Uno de los modelos más utilizados es el *Fire Spread Model* de Rothermel (1972), el cual es muy sensible al L-FMC en la mayoría de los tipos de combustibles. Jolly (2007) encontró, por ejemplo, que un 10 % de diferencia en el L-FMC podría producir hasta un 1.200 % de diferencia en la predicción de la propagación del fuego (*Rate of Spread*).

Es importante destacar que la exactitud es, entonces, relevante para la gestión del riesgo de incendios forestales. Así, muchos estudios (ejemplos: Chuvieco *et al.*, 2004b; Dennison *et al.*, 2005; Jurdao *et al.*, 2013; Peterson *et al.*, 2008; Stow *et al.*, 2006, 2005; Yebra *et al.*, 2008b, entre otros) reportaron estimaciones del L-FMC con errores de R^2 , RMSE (*Root Mean Square Error* – Error Cuadrático Medio) ó MAE (*Mean Absolute Error* – Error absoluto medio). A su vez, no se puede comparar los estudios, ya que hay bastantes diferencias en las metodologías empleadas y en la exactitud reportada. Algunas diferencias son de calibración y procedimientos de validación, el tipo de sensor utilizado, el lugar estudiado, los protocolos de recolección de las muestras y procesamiento, etc.

- Los errores en el L-FMC estimado son de vital importancia para determinar el riesgo de un incendio. Un error de un 20 % sumado o restado a un L-FMC de 90 % resultaría en riesgo bajo para, por ejemplo, pastizales (*Shrublands*) (Probabilidad de Ignición (IP) de un 19 % asociado a un L-FMC = 110 %), a alto (IP = 60 % asociado a un L-FMC = 70 %), cuando la probabilidad de ignición es calculada como la propuesta por Chuvieco *et al.* (2004a).

2.3.8 Trabajo de campo

Al hablar sobre trabajo de campo se alude a lo intrínseco de la experiencia en materia de recolección de muestras de vegetación en determinado sector para su posterior análisis en laboratorio. En virtud de lo anterior, existen una serie de estudios enfocados en establecer protocolos para la extracción de muestras, con el objeto de luego ser utilizadas para determinar la cantidad de humedad como porcentaje de biomasa i.e. estimar el FMC. Así, a continuación se analizarán algunas condiciones establecidas a partir de lo hallado en la literatura.

[Desbois et al. \(1997a\)](#) establecen un protocolo para la recolección de muestras con la finalidad de analizar el *Fuel Moisture Content* (FMC). Todo lo anterior se remonta, justamente, para el estudio de la gestión del riesgo de incendios por medio de índices espectrales obtenidos a partir de información satelital. La primera restricción es el lugar de recolección, en donde la variable principal es la resolución espacial de un sensor satelital y su relación con la homogeneidad de la vegetación a estudiar. En efecto, claramente no se puede analizar, por ejemplo, con un sensor satelital que tiene una resolución espacial de 100 metros una zona, dentro de dicha resolución, en donde se encuentre una heterogeneidad de vegetación, así como espacios amplios de suelo que afectarían a la señal recibida por el sensor (lo cual ya se estudió indirectamente con los índices espectrales de la [Tabla 2.4](#) en la [Sección 2.2.4 – Índices Espectrales](#)).

Otras restricciones de las que se pronuncian en el estudio de [Desbois et al. \(1997a\)](#) tienen relación con la topografía del sector, y aluden a que ésta debiese ser lo más homogénea posible. En cuanto a la obtención de las muestras, establecen que medidas entre 100 a 200 gr son suficientes para un análisis de FMC, y que se debiesen de colocar en bolsas herméticas con el fin de conservar su contenido de humedad en el traslado hacia el laboratorio.

Por otro lado, también se encuentra el manual técnico de la *U.S Department of Agriculture – Forest Service* (USDA, Departamento de Agricultura de EE.UU y el Servicio Forestal) para la recolección de muestras ([Zahn y Hensen, 2011](#)). En éste, se hace énfasis que para la recolección de muestras vivas es importante no concentrarse en obtener muestras tan internas a la vegetación, debido a que el combustible puede presentar, en materia de fenología, tanto follaje senescente (“de edad”) o efímero (“joven”). También, hacen énfasis en no recolectar vegetación enferma o dañada. A su vez, establecen que variaciones de hasta un 20 % en el contenido de humedad es común incluso si la recolección es bien realizada. Otro factor que se recalca en el protocolo de la USDA es que para recolectar combustibles vivos, si éstos presentan gotas de agua en las hojas o en los tallos, no se deben recolectar, debido a que afectará a los resultados ([Zahn y Hensen, 2011](#)).

[Chuvieco et al. \(2004a\)](#) establecen que para asegurar la significancia espacial y temporal, las medidas deben ser realizadas en diferentes sitios y periodos. A su vez, se basan en estudios de otros autores como [Desbois et al. \(1997a\)](#) para establecer que la hora recomendada para realizar las muestras es al rededor del medio día (12:00 – 14:00), cuando el FMC es bajo y por lo tanto las condiciones de riesgo aumentan ([Desbois et al., 1997a](#)).

Por último, [Aguado et al. \(2004\)](#) (pág. 51) consideran que la opción más común para la obtención de las muestras, que catalogan como “simple, reproducible y coherente”, es centrarse en los brotes terminales (hojas y ramas pequeñas).

La metodología más común para la obtención del FMC radica en la utilización de un horno que es capaz de secar las muestras con el fin de obtener el peso seco de las mismas. Así, en términos simples, consiste en pesar la muestra fresca y luego introducirla al horno a cierta temperatura y tiempo, para

luego pesarla nuevamente y así obtener su masa seca. Luego, con la ecuación del FMC se tiene que:

$$\text{FMC} = \frac{W_f - W_d}{W_d} \cdot 100 \%$$

En donde W_f y W_d corresponden al peso fresco y el peso seco en gramos, respectivamente.

Las metodologías para cierta temperatura y tiempo de secado son bastante variadas para esta técnica, en la literatura se encontraron investigadores que utilizaban temperaturas desde los 60 hasta los 105°C y tiempos de secado de entre 4 y 72 horas. La [Tabla 2.5](#) presenta una recopilación bibliográfica del secado de muestras con ésta metodología.

Autor	Temperatura (°C)	Δt (horas)
Van Wagner <i>et al.</i> (1967)	100	24
Trabaud (1976)	80	48
Caramelle y Clément (1978)	60	24
Loomis y Main (1980)	105	24
Chrosciewicz (1986)	100	24
Valette (1986)	60	36
Dimitrakopoulos y Papaioannou (2001)	105	48
Jurdao <i>et al.</i> (2014)	60	48
Asner <i>et al.</i> (2011)	70	72
Piñol <i>et al.</i> (1998)	105	24
Viegas <i>et al.</i> (1998)	100	24
Desbois <i>et al.</i> (1997b)	60	48
Viegas <i>et al.</i> (1992)	100 ± 5	4
Simard y Main (1982)	105	24
Martín y Lara (1989)	60	24
Desbois <i>et al.</i> (1997a)	60	48

Tabla 2.5: Recopilación bibliográfica del secado de muestras con la metodología del *Ovendry Weight*.

Fuente: Elaboración propia.

3 | Métodos y Materiales

En el presente capítulo se darán a conocer el área de muestreo, la especie, los instrumentos a utilizar y, por último, la metodología de la experimentación, es decir, los pasos que se seguirán para poder lograr los objetivos del proyecto. El esquema que da a conocer los temas a tratar se puede apreciar en la [Figura 3.1](#).

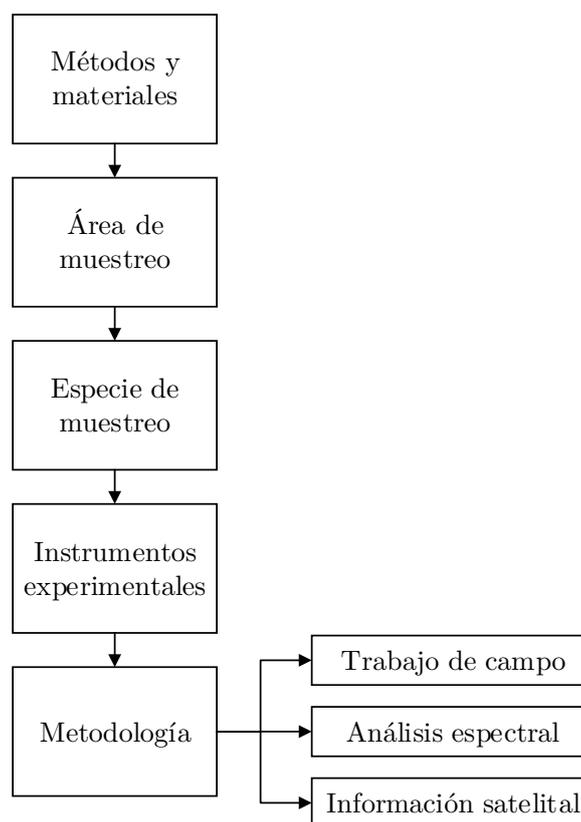


Figura 3.1: Esquema de los contenidos a tratar.
Fuente: Elaboración propia.

3.1. Área de muestreo

Las muestras de vegetación se obtendrán en la Reserva Nacional Lago Peñuelas, ubicada en el Km 89 de la Ruta 68, en la V Región de Valparaíso – Chile, con coordenadas: 267.301 y 6.324.652 (huso 19 Sur). La reserva cuenta con un sector de alrededor de 200 hectáreas, que fue concesionada por CONAF a Ecoturismo Peñuelas con el objetivo de ofrecer a los visitantes una oferta turística mejorada y más diversa. Entre las ofertas turísticas se encuentran actividades de camping, picnics, entre otras.

La razón de elección de éste lugar es debido a que cuenta con extensas áreas de Pino Radiata (la especie de muestreo – ver la [Sección 3.2](#)), en un lugar seguro y protegido por la CONAF. Una de las restricciones que se tiene para la elaboración del proyecto es la utilización de imágenes satelitales de libre acceso, cuyas imágenes en la región espectral a analizar tienen una resolución de 30 metros cuadrados. De esta forma, se busca idealizar que en 1 píxel esté contenido solo 30 metros cuadrados de pino radiata. Se comunicó con don Aldo José Valdivia Ahumada (Administrador de la Reserva Nacional Lago Peñuelas de CONAF) y se le comentó sobre el proyecto y en lo que constaba, recibiendo

de su parte el apoyo para la toma de muestras en la reserva.

3.2. Especie de muestreo

La especie utilizada para la experimentación es el Pino Radiata, que también es conocida como Pino Insigne, Pino de Monterrey o Pino de California.

3.2.1 Descripción general de la especie

El pino radiata es una conífera perteneciente a la familia de pinos *Pinaceae*, son nativos de California y Baja California (EE.UU). Se caracterizan por poseer agujas de color verde oscuro de tipo perenne que crecen en grupos de a tres, donde el largo de éstas puede variar entre 6 a 15 cm. Los conos son asimétricos y de un color café oscuro, estos nacen en grupos de entre tres a siete y poseen entre 120 a 200 semillas, las cuales solo se desprenden si éstas son sometidas a altas temperaturas. Los pinos más maduros pueden llegar a medir 38 metros de altura con troncos de hasta 2 metros de diámetro. Esta especie se ha propagado por Latinoamérica, específicamente en países con climas mediterráneo dado la naturaleza de la especie, con la finalidad de ser utilizado como fuente de madera y papel (USDA, 2002).

Chile cuenta con una amplia industria forestal, la cual se basa en las plantaciones de especies no-nativas para la producción de celulosa. Estas plantaciones se encuentran en el centro y sur del país. Un total de 17,5 millones de hectáreas, que representan el 23 % de la superficie total de tierra de Chile, corresponden a bosques. De estos, el 15 % i.e. 2,6 millones de hectáreas, corresponden a plantaciones de árboles. Se estima que el 60 % de los 2,6 millones de plantaciones corresponden a *pino radiata* (1,56 millones de hectáreas) y el resto se reparte (al rededor de un 35 %) entre *eucalyptus globulus* y *eucalyptus nitens* (Reszka, 2017a). El alcance de las plantaciones de Pino Radiata ha crecido rápidamente en las últimas décadas, especialmente en las zonas mediterráneas del país (zonas centrales) (Becerra y Bustamante, 2008). Según la CONAF, de la superficie afectada en cada período de incendios forestales, el mayor daño corresponde a praderas y matorrales. En menor escala arbolada natural y plantaciones forestales, principalmente se distingue, entre estas, el pino insigne (CONAF, 2016c).

Algunos datos sobre las características del combustible bajo estudio son (Muñoz-Feucht *et al.*, 2014):

- Densidad (ρ_f):

$$\rho_f = 898,57 \left[kg m^{-2} \right]$$

- Ratio Superficie – Volumen (α_k):

$$\alpha_k = 4,7 \left[mm^{-1} \right]$$

En la [Tabla F.1](#) del [Anexo F](#) se pueden apreciar algunas características en relación a la composición elemental de las agujas y conos de pino radiata.

3.3. Instrumentos Experimentales

En la presente sección se darán a conocer los instrumentos/herramientas que se utilizarán para poder lograr los objetivos del proyecto.

3.3.1 Espectrometría de campo

Un problema asociado a la “Espectrometría de campo”, radica en el control de la reflectividad difusa y de fondo. El proyecto considera la adquisición u medición de un espectro continuo de la vegetación. Por ende, al considerar solo el espectro de determinada muestra, resulta imprescindible intentar que así sea. De esta forma, es importante estudiar las características técnicas del instrumento óptico para realizar análisis espectral. El instrumento corresponde a un espectrómetro fabricado por la empresa OceanOptics y el modelo es “STS–NIR” (ver la [Figura 3.2a](#)), cuyas características se pueden apreciar en la [Tabla 3.1](#).

Tabla 3.1: Características del espectrómetro y de la fibra óptica.

Fuente: Elaboración propia a partir de [OceanOptics \(2016c,d\)](#)

CARACTERÍSTICAS TÉCNICAS DEL ESPECTRÓMETRO STS-NIR	
Fabricante	OceanOptics
Modelo	STS-NIR; Miniature Spectrometer
Rango Espectral	650 – 1.100 nm
Rango dinámico	4.600:1
Signal-to-noise	> 1.500:1
Resolución (ancho de banda)	1,5 nm
Dimensiones	40 mm × 42 mm × 24 mm
Peso	60 gr
Detector	ELIS1024
Fibra óptica	Entrada SMA 905
Ángulo de visión de la fibra óptica	~25°

El espectrómetro viene calibrado por el fabricante (OceanOptics). Mediante la [Tabla 3.1](#) es importante destacar tres parámetros relevantes: el rango espectral (650 – 1.100 nm), la resolución óptica (1,5 nm) y el ángulo de visión de la fibra óptica (~25° – [OceanOptics, 2016d](#)).

Se cuenta, también, con un soporte para conectar la fibra óptica y poder controlar la altura. Dicho soporte es de la empresa THORLABS y el modelo del soporte es el RPS–SMA (*Adjustable Fiber Optic Probe Stand with SMA Connectors* – ver [Figura 3.3](#)). El beneficio de utilizar un soporte es para evitar errores al momento de realizar las mediciones espectrales a las muestras, es decir, minimizar el ruido del fondo gracias a la superficie que posee el soporte y, a su vez, controlar la altura, que es sumamente relevante considerando que la fibra óptica cuenta con un ángulo de visión de, aproximadamente, 25°, como se dijo anteriormente.

Para calibrar el instrumento (para la adquisición de muestras) es necesario contar con un estándar de reflectancia difusa (el cual reflejaría un 100 %) y una fuente que absorba toda luz (un paño negro), en donde la reflectancia sea de un 0 % para el espectro observado. Para el caso del estándar de reflectancia difusa se utilizará el Estándar WS–1 de OceanOptics (ver la [Figura 3.2b](#)), cuyo material se comporta de forma lambertiana con una reflectividad superior al 98 % entre los 250–1.500 [nm] ([OceanOptics, 2016e](#)).

La Fibra Óptica que se utilizará tiene dos metros de longitud y un diámetro de 600 [nm], trabaja con longitudes de onda comprendidas en el rango UV–VIS, con puerto de entrada SMA 905 y un ángulo de visión de ~25° ([OceanOptics, 2016c,d](#)).



Figura 3.2: (a) STS–NIR: Espectrómetro utilizado para el análisis espectral de la vegetación y (b) el estándar WS–1 para la calibración del espectrómetro.

Fuente: OceanOptics (2016c,e).



Figura 3.3: Montura para la fibra óptica: THORLABS RPS–SMA.

Fuente: Elaboración propia.

3.3.2 Información satelital

La información satelital hace referencia a las imágenes de sensores satelitales que se utilizarán para cumplir con los objetivos propuestos en el proyecto, las que corresponden a las del satélite Landsat 8 del USGS (*United States Geological Survey*). Estas imágenes se adquieren directamente de la plataforma GLOVIS (<http://glovis.usgs.gov/>) del USGS, siendo de libre acceso. El satélite cuenta con una resolución temporal de 16 días y una resolución espacial de 30 metros en el canal visible (VIS), infrarrojo cercano (NIR) y en el infrarrojo de onda corta (SWIR), versus 15 metros en el canal pancromático (entre las longitudes de onda de 503 a 676 nm) (USGS, 2015a). A su vez, el ancho de barrido del sensor (swath) es de 190 km con una resolución radiométrica de 16 bits. Cabe destacar que el peso promedio de una sola imagen es de, aproximadamente, 1,0 GB. Por otro lado, es importante decir que se trabajará con el programa ENVI versión 5.3 para el procesamiento de las imágenes provenientes del satélite Landsat 8.

Es importante destacar que existe una variable implicada para la obtención de las variables estudiadas en el laboratorio con el fin de poder “escalar” sus resultados a nivel satelital. Esta corresponde al *Leaf Area Index* (LAI – ver Sección 2.3.1) la cual, por motivos de eficiencia, se obtendrá a partir de del producto MCD15A2H (*MODIS/Terra+Aqua Leaf Area Index/PPAR 8-Day L4 Global 500m SIN Grid V006*) del sensor MODIS de NASA (Myneni y T.Park, 2015). Las descargas de las imágenes se realizaron a través de la plataforma REVERB ECHO de NASA en el siguiente url: <https://reverb.echo.nasa.gov/>. Cabe mencionar que, para todas las experiencias, el *tile* (escena) correspondiente es el h12v12 (horizontal 12 y vertical 12). Luego, estas imágenes se abrieron en el programa QGIS (versión 2.12.3), se seleccionó la capa del LAI y luego se añadieron los puntos por experiencia a cada imagen y así se obtuvo el valor para cada uno de éstos. Los productos LAI utilizados se encuentran en la etapa 2 de validación, lo que significa que la certeza del producto está estimado sobre un conjunto significativo de sectores y períodos de tiempo con información *in situ*. A su vez, la consistencia espacial y temporal del producto con otros similares ha sido evaluada en diversas partes del mundo.¹

3.3.3 Otros

3.3.3.1 Horno para el secado de muestras

El horno para el secado de las muestras es de la marca Memmert, modelo UN30. Dentro de sus características, la temperatura y tiempo de operación son regulables entre 5–300°C con resolución de 0,1–0,5°C, dependiendo del tramo de temperaturas en el que se esté operando. En tanto, el tiempo se puede configurar entre 1 minuto hasta 99 días (Memmert, 2016). En la Figura 3.4a se puede apreciar el aparato.

3.3.3.2 Balanza

Para pesar las muestras frescas y secas (antes y después del secado en el horno) es necesario contar con una balanza de precisión. La que se utilizará en las experiencias corresponde a la balanza marca KERN modelo PFB. Esta balanza tiene una capacidad máxima de 120 [gr] y lectura mínima de 0,001 [gr] (KERN, 2016). En la Figura 3.4b se puede apreciar una imagen del instrumento.

3.3.3.3 GPS

Para poder determinar la ubicación geográfica de los pinos a los cuales se les extraerán las agujas, se utilizará un GPS marca Garmin modelo etrex Vista HCx. Dentro de las características más importantes se encuentran una precisión de ± 5 grados del compás y una precisión de ± 10 pies en el altímetro. A

¹Fuente: <https://landval.gsfc.nasa.gov/>



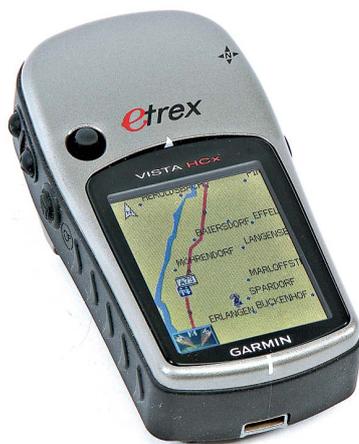
(a)



(b)

Figura 3.4: (a) Horno y (b) balanza utilizados en la experimentación.

Fuente: Ambos se obtuvieron del manual. Horno: [Memmert \(2016\)](#) y Balanza: [KERN \(2016\)](#).



(a)



(b)

Figura 3.5: (a) GPS y (b) Tijeron utilizados en la experimentación.

Fuente: GPS: [Ridalbolivia \(2016\)](#) y Tijeron: Elaboración propia.

su vez, la precisión de GPS es menor a 10 metros, 95 % típica ([Garmin, 2007](#)). En la [Figura 3.5a](#) se puede apreciar una imagen del instrumento.

3.3.3.4 Tijerón

Para cortar las ramas de los pinos se utilizará un tijerón marca Roots Garden modelo RGH024. En la [Figura 3.5b](#) se puede apreciar una imagen del instrumento.

3.3.3.5 Computador

Para el procesamiento de las imágenes satelitales se utilizará un computador armado por el autor del proyecto. El computador cuenta con procesador intel core i7 de 4 núcleos, 16GB de memoria RAM de 2.400 Mhz, tarjeta gráfica de 4GB y un disco de estado sólido (SSD) de 500GB.

3.4. Metodología

En esta sección se darán a conocer los pasos a seguir para poder lograr los objetivos del proyecto. Las muestras a analizar son agujas de pino radiata de vegetación viva, extraídas directamente de los pinos. Estas se cortarán con el tijerón y luego se le extraerán las agujas de pino para ser guardadas en bolsas herméticas con su respectiva ubicación geográfica gracias al GPS. La muestra de un pino se utilizó para el análisis espectral en conjunto con el estudio de laboratorio (secado en el horno y pesaje) con el fin de obtener el FMC y otras variables asociadas.

Por otro lado, es importante destacar que se seleccionaron las agujas de pino por sobre las ramas o troncos debido a las siguientes razones:

1. Simplificar el trabajo de campo.
2. Por ser la sección de vegetación más crítica en cuanto a la propagación del fuego (Aguado *et al.*, 2004).
3. Por representar una porción relevante del combustible consumido durante los incendios forestales (Jervis y Rein, 2016).
4. Se puede considerar que la reflectancia de las hojas es capaz de revelar las variaciones que éstas experimentan como consecuencia de cambios ambientales (Vaughan, 2001).

A continuación se presentará el detalle de la metodología para cada tipo de análisis, pero primero se introducirá con la metodología que alimenta a todos los estudios, es decir, el trabajo de campo en materia de recolección de las muestras.

3.4.1 Trabajo de campo experimental

En la Sección 2.3.8 se mencionaron algunos protocolos establecidos para el estudio del FMC. Es así como en base a dichos protocolos se realizará la metodología para la recolección de muestras considerando tres aspectos sumamente relevantes.

1. Desbois *et al.* (1997a) plantean que la zona en donde se realizará la recolección debe ser lo suficientemente homogénea con el fin de poder escalar, más tarde, los resultados del laboratorio a nivel del dosel y así poder estimarlos por medio de información satelital. Es así como la zona electa cumple con éstas restricciones, en donde se presentan extensas áreas de la vegetación bajo interés. A su vez, la región presenta una baja visibilidad del suelo si es observada desde arriba. En cuanto a lo anterior, Desbois *et al.* (1997a) no lo establecen como tal, pero se puede inferir que se alude al concepto del LAI (*Leaf Area Index*, como se analizó en la Sección 2.3.1), es decir, lo que establecen es que la zona tenga una baja razón entre el área cubierta por la vegetación y el área cubierta por el suelo.
2. La extracción de las muestras considerará lo propuesto por el protocolo de recolección de la USDA (Zahn y Hensen, 2011), en donde la vegetación a recolectar no debe presentar agua ni en hojas ni en tallos, para que no se alteren los resultados experimentales.
3. La recolección se hará considerando lo propuesto por Aguado *et al.* (2004) i.e. la opción más simple, reproducible y coherente, que se centra en la recolección de brotes terminales (hojas y ramas pequeñas). Así, de cada rama de vegetación obtenida habrá un trabajo asociado a la extracción de los brotes terminales, que vendrían siendo las agujas de pino. La cantidad a recolectar para el estudio del FMC rondará los, aproximadamente, 200 gr.

En base a lo anterior, el procedimiento consiste en la recolección de las muestras al día siguiente del paso del satélite con el fin de corroborar que la imagen no tenga ruido. La recolección se realizará

a la misma hora del paso del satélite por el sector de recolección (al rededor del medio día), y consiste en cortar ramas de las extremidades del árbol con un tijerón. Luego, se extraen de éstas las agujas de pino para luego almacenarlas en bolsas herméticas para su traslado al laboratorio. En cada bolsa se anotará el número de pino que irá de la mano con una determinada coordenada geográfica a partir del uso del GPS. De esta forma, el proceso se puede apreciar visualmente en la [Figura 3.6](#).

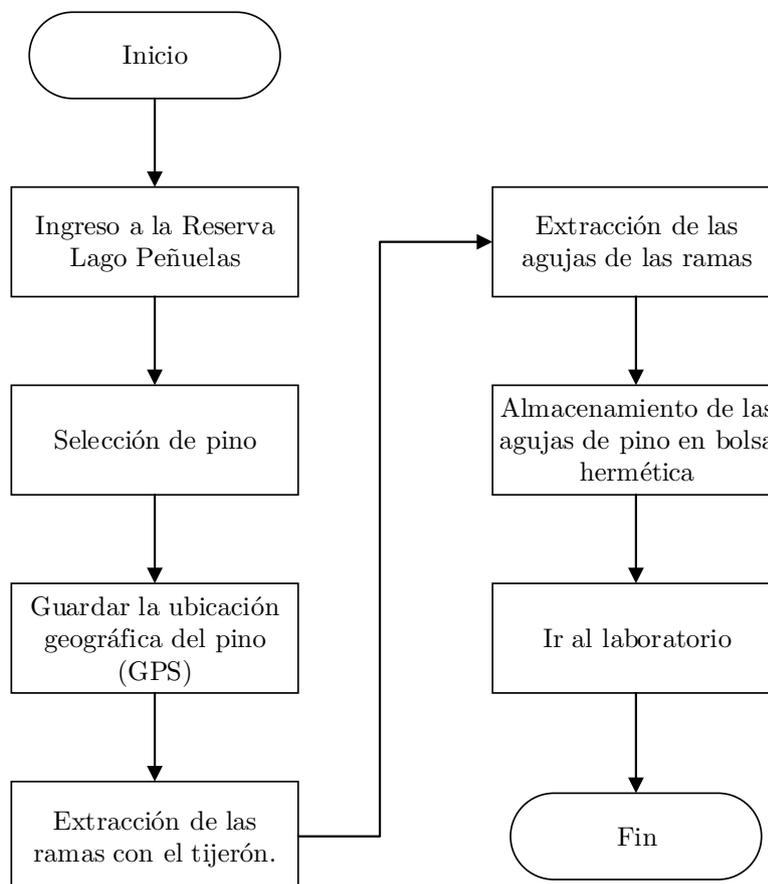


Figura 3.6: Proceso de recolección de muestras
Fuente: Elaboración propia.

De esta forma, cada vez que se viaje a la Reserva Lago Peñuelas se realizará la recolección para tres o más pinos. Estos pinos estarán a una distancia de manera tal que se encuentren a más de 30 metros de distancia entre ellos, con el objeto de que no se hallen más de uno dentro de un mismo píxel de la imagen satelital del satélite Landsat 8. A partir de esto es que, entre muestras, se calcularán > 40 pasos hasta la próxima extracción.

El análisis de laboratorio para la presente experiencia alude al cálculo del contenido de humedad de la vegetación como porcentaje de la biomasa, es decir, es el cálculo para estimar el *Fuel Moisture Content* de vegetación viva. Así, la técnica a emplear es la del *Ovendry Weight* (o secado en horno). Dicho proceso consiste en secar las muestras de vegetación por medio de un horno especializado, que permite ajustar la temperatura y el tiempo. El horno es el modelo UN30 de la marca Memmert (como se dio a conocer en la [Sección 3.3](#)).

El primer paso es la obtención del peso fresco de las muestras (W_f). Así, se procede a pesar la muestra en la balanza de precisión. Luego, las muestras se situarán sobre una bandeja que se colocará dentro del horno. La temperatura que se utilizará será de 60° por 24 horas. La razón de dichos tiempos viene dado debido a que se encontraron varios estudios que utilizaron tal tiempo y temperatura (ver la

Tabla 2.5 en la Sección 2.3.8), concluyendo, la mayoría, que luego de 24 horas a 60° las muestras ya no seguían perdiendo humedad. Por otro lado, el empleo de éste valor permite evitar pérdidas indeseadas de masa debido a la pirólisis (Castro *et al.*, 2014). Cabe destacar que ya se ha trabajado con el horno ayudando a Carola Contreras (Contreras, 2016) en su proyecto de título, en donde se pudo dar cuenta que con temperaturas mayores existía un prominente olor a hojas quemadas. Luego de transcurrido dicho tiempo, es necesario masar nuevamente la muestra, con el fin de obtener su masa seca (W_d). Como ya se examinó con anterioridad, el FMC se calcula como:

$$\text{FMC} = \frac{W_f - W_d}{W_d} \cdot 100 \%$$

En donde W_f y W_d corresponden al peso fresco y el peso seco en gramos, respectivamente.

La cantidad de pinos a las cuales se les extraerá muestra equivalen a un mínimo de tres por cada experiencia (viaje a la reserva y trabajo de laboratorio) y un máximo de cinco. La limitación se debe a que para cada pino se hará un análisis del FMC en donde el investigador se ve limitado por la cantidad de espacio en el horno para el secado de éstas.

3.4.2 Análisis espectral

Luego de recolectar las muestras y llegar al laboratorio en la Universidad Técnica Federico Santa María (Casa Central – Valparaíso), la metodología aplicada al análisis espectral consiste en realizar las experiencias al aire libre en las dependencias de la universidad. Es decir, se realizará bajo condiciones naturales de iluminación. La razón de lo anterior, es que se busca tener una luz lo más similar a lo que sería la captada por un sensor satelital. Para cada experiencia espectral (una muestra) se realizarán cinco mediciones del espectro de reflexión entre los rangos espectrales capturados por el espectrómetro STS–NIR. Estas cinco mediciones se promediarán para dar lugar al resultado de una experiencia, dado que existe una alta variabilidad experimental que son intrínsecas a la naturaleza de este tipo de experiencias (Datt, 1998). Importante es el destacar que según los resultados expuestos por Vaughan (2001), la irradiación solar presenta mayor variación en la región de los 3.000 nm, por lo que no se alterarán los resultados de las experiencias (dado que la porción del espectro que se estudia con el STS–NIR es entre los 650 – 1.100 nm). Las experiencias se realizarán al medio día ($\pm 1,5$ horas) a un ángulo de 90°, comprendido entre la fibra óptica y las muestras (lo que se denomina “nadir”). Las bases del porqué utilizar estas configuraciones para la experiencia yacen en los supuestos realizados por Vaughan (2001), que son los siguientes:

- La referencia del blanco cubre el campo de observación del sensor (FOV).
- Las propiedades del blanco son conocidas e invariables durante las experiencias.
- La iluminación no varía en el lapso de tiempo entre que se mide el blanco y la superficie analizada.
- No hay dispersión de luz en la atmósfera, ausencia de luz difusa.

No obstante, los últimos dos supuestos no se cumplen en su totalidad, dado que es imposible controlar la intensidad de la radiación solar. Dado lo anterior, es que se busca minimizar los errores de las mediciones, por ende es fundamental disminuir los tiempos entre la calibración del instrumento y la adquisición del espectro por parte del instrumento óptico. Es así como para cada una de las 5 mediciones de una muestra, el aparato se calibra nuevamente, siendo revisado enseguida con la referencia del blanco y negro, donde reflejaría un 100 % y un 0 %, respectivamente, que se puede observar visualmente en el software del espectrómetro (OceanView).

3.4.2.1 Simulación del espectro de reflexión

Debido a que el rango espectral que el espectrómetro es capaz de capturar no tiene regiones en el SWIR (*Shortwave Infrared* – Infrarrojo de onda corta), es necesario encontrar métodos para poder obtener las reflectancias en aquellas longitudes de ondas. Como se estudió en la Sección 2.2.3.3, existen modelos de transferencia radiativa (*Radiative Transfer Models* – RTM) que permiten realizar lo anterior con bastante precisión. La simulación del espectro se llevará a cabo utilizando PROSPECT, un RTM a nivel de hoja que tiene como finalidad el simular el espectro de reflexión entre los 400 – 2.500 nm, el cual requiere tanto parámetros físicos como químicos para su ejecución (Ferret *et al.*, 2008; Jacquemoud y Baret, 1990). Dichos parámetros son los siguientes (OpticLeaf, 2015b):

- Estructura Interna (N)
- Contenido de Clorofila (C_{a+b})
- Contenido de Carotenoides (C_{car})
- Pigmentos Café (C_b)
- Equivalent Water Thickness (EWT_{Leaf})
- Leaf Mass per Area (LMA)

De estos, algunos parámetros provendrán directamente de la información espectral obtenida por el STS–NIR, del análisis de laboratorio y de ajustes matemáticos estadísticos. A continuación se dará a conocer el cómo se obtendrán cada uno de ellos.

a) Contenido de Clorofila y Carotenoides

La clorofila, los carotenoides y los pigmentos café corresponden a pigmentos fotosintéticos de vegetación. En tanto, cabe destacar que los valores de clorofila a calcular son las denominadas “a” y “b” (C_{a+b}). Tanto la clorofila (a+b) como los carotenoides, serán determinados a partir de un índice espectral denominado “Índice de Gitelson” (I.G – Gitelson *et al.*, 2003), un índice que permite obtener, indirectamente, el contenido de clorofila a partir de medidas de reflectancia de forma no destructiva.

Se utilizará la base de datos LOPEX 93 (*Leaf Optical Properties Experiment 93*, Hosgood *et al.*, 1994 – ver la Sección 2.2.3.3.1 para más información de LOPEX93), a la cual se le realizará una regresión lineal a los datos de clorofila (C_{a+b}) y carotenoides (C_{car}) con respecto al I.G para obtener un modelo y luego utilizarlo en el presente proyecto. El fin es conseguir, indirectamente, el contenido de clorofila (C_{a+b}) y de carotenoides (C_{car}) en unidades de $\mu\text{g}/\text{cm}^2$, para ambos casos, de las muestras experimentadas.

El Índice de Gitelson (I.G) es el siguiente (Gitelson *et al.*, 2003):

$$\frac{\rho_{NIR}}{\rho_{\lambda}} - 1 = \frac{\rho_{750-800}}{\rho_{695-740}} - 1 \quad (3.1)$$

Las relaciones que se utilizarán se comportan de forma lineal según lo estudiado por Gitelson *et al.* (2003) (en cuanto al índice propuesto y la variable independiente – C_{a+b} y C_{car}). Por lo tanto, la clorofila (a+b) como los carotenoides se obtendrán a partir de las siguientes expresiones:

$$C_{a+b} = a \cdot \left(\frac{\rho_{NIR}}{\rho_{\lambda}} - 1 \right) + b \quad (3.2)$$

$$C_{car} = c \cdot \left(\frac{\rho_{NIR}}{\rho_{\lambda}} - 1 \right) + d \quad (3.3)$$

En donde a , b , c y d son constantes de la regresión lineal que se obtendrán al aplicar las ecuaciones a la base de datos de LOPEX93 para muestras frescas, dado que en la base de datos se conocen la cantidad de carotenoides (C_{car}) y clorofila (C_{a+b}) para las especies muestradas en ella, así como sus reflectancias entre los 400 – 2.500 nm .

Para facilitar el análisis, las medidas de reflectancia que se utilizarán en el Índice de Gitelson corresponden a los valores medios, es decir, para la región del NIR (ρ_{NIR}) se utilizará el valor de 775 nm y para ρ_λ se utilizará el valor de 718 nm .

Los pigmentos café serán determinados de forma visual. Dado que se trabajará con vegetación viva (fresca), se supondrá que no se encuentran pigmentos café, que son característicos de vegetación en fase de senescencia (Jacquemoud y Baret, 1990). PROSPECT supone valores entre 0 y 1 para pigmentos café, en donde 1 correspondería a una hoja completamente café y un valor 0 una hoja con total ausencia de dichos pigmentos. Para el presente experimento, se utilizará un valor de 0, dado que se trabajará siempre con vegetación verde y viva recolectada de pinos silvestres de la Reserva Lago Peñuelas.

b) Parámetro de estructura interna (N)

El parámetro de estructura interna representa la anatomía de la hoja, que corresponden al número de capas homogéneas elementales apiladas que conforman la hoja. Este parámetro presenta una alta relación con el SLA (*Specific Leaf Area* – [cm^2/gr] (gr = gramos de masa seca) Asner *et al.*, 2011) (Jacquemoud y Baret, 1990).

En la literatura se encontraron dos relaciones para obtener el valor de éste parámetro (N), ambas en función del SLA.

La primera relación (3.4) corresponde a un ajuste hiperbólico entre N y el SLA (Jacquemoud y Baret, 1990):

$$N = \frac{0,9 \cdot SLA + 0,025}{SLA - 0,1} \quad (3.4)$$

La segunda relación (3.5) corresponde a una fórmula propuesta por Veroustraete y Gond (Ceccato *et al.*, 2001):

$$N = \sqrt[4]{\frac{1}{SLA - 0,1}} \quad (3.5)$$

Es importante destacar que $SLA=LMA^{-1}$, en donde las unidades del LMA corresponden al cociente entre la masa seca de la muestra y el área de la misma (Asner *et al.*, 2011) ó, en otras palabras, equivale al DMC.

Los rangos que éste parámetro soporta varían entre 1,0 y 3,0 (OpticLeaf, 2015a), en donde valores de N entre 1,0 y 1,5 corresponden a plantas monocotiledóneas con mesófilo compacto, las dicotiledóneas son asociadas a valores en el rango entre 1,5 y 2,5. Por último, valores de $N > 2,5$ se atribuyen a la fase de senescencia de las hojas con una estructura interna desorganizada (Jacquemoud y Baret, 1990).

c) Equivalent water thickness (EWT)

Como se estudió en la Sección 2.3.3, el *Equivalent Water Thickness* es la cantidad de agua por unidad de área de la hoja en donde se asume un hipotético grosor de una sola capa de agua

promediada a lo largo de toda el área de ésta (Danson *et al.*, 1992).

Así, el EWT se define matemáticamente como:

$$\text{EWT} = \frac{W_f - W_d}{A}$$

Donde W_f corresponde al peso fresco (*fresh weighth*), W_d corresponde al peso seco (*dry weighth*) y A corresponde al área de la hoja.

La obtención del EWT, en unidades de g/cm^2 , se puede obtener de dos formas: indirecta (no destructiva) y directa (destructiva). La indirecta contempla un cálculo similar al de la clorofila y carotenoides, en donde se obtienen los coeficientes de regresión lineal para los datos de la base de datos de LOPEX93 (que incluyen los valores de EWT para las muestras de la base de datos – Hosgood *et al.*, 1994). La metodología no–destructiva viene a partir del estudio realizado por Mobasheri y Fatemi (2013), en donde se propusieron tres ecuaciones para relacionar el EWT con índices espectrales (ver la Sección 2.3.3 para más detalles). La ecuación a utilizar es la Ecuación 2.27, que dice:

$$\text{EWT} = a \cdot \left(\frac{R_{\lambda_i}}{R_{\lambda_j}} \right) + b$$

En donde R_{λ_i} corresponde al valor de reflectancia en la longitud de onda 'i', R_{λ_j} corresponde al valor de reflectancia en la longitud de onda 'j', 'a' y 'b' corresponden a los coeficientes de la regresión lineal. En los resultados del estudio realizado por Mobasheri y Fatemi (2013) se encontraron muy buenas relaciones ($R^2 \geq 0,9$) entre reflectancias en longitudes de onda del rango 741 – 1.376 [nm]. De esta forma, el índice que se utilizará para poder realizar la regresión y que, a su vez, se podrá estimar a partir de los datos obtenidos por el espectrómetro, es el *Water Index* (WI – Peñuelas *et al.*, 1997, más información en la Sección 2.2.4). Este índice establece la siguiente relación:

$$\text{WI} = \frac{R_{900}}{R_{970}}$$

Así, el valor R_{900} y R_{970} corresponden a los valores de reflectancia a los 900 y 970 nm, respectivamente. Luego, la relación para estimar el EWT a partir del modelo estadístico (indirectamente) es:

$$\text{EWT} = a \cdot \left(\frac{R_{900}}{R_{970}} \right) + b$$

Donde los valores del EWT y de las reflectancias provienen de la base de datos de LOPEX93. Por otro lado, la metodología destructiva contempla el cálculo del EWT en el laboratorio, es decir, calculando el área de la hoja en conjunto con su peso fresco y seco, por lo que implica el uso del horno y la metodología para el cálculo del FMC. En este estudio se aplicarán ambas metodologías, dado que de una u otra forma se examinará destructivamente la vegetación para la obtención del FMC. Ahora bien, surge un nuevo problema, que es el cálculo del área de la aguja de pino. Este se resolverá de una forma bastante práctica, que contempla el uso de la cámara de un celular y el procesamiento de la imagen en un programa de libre acceso (*ImageJ*). El proceso completo se puede apreciar en el Anexo H. En síntesis, consiste en tomar una fotografía a 10

agujas de pino representativas de la muestra para el FMC (que previamente se pesan, luego se meten al horno por separado y se pesan nuevamente) sobre una hoja blanca con una regla en la parte inferior. Con el programa se le da una medida en base a la regla, luego se seleccionan las agujas con un ajuste de contraste, y se procede a calcular sus áreas.

d) Leaf mass per area (LMA)

El LMA es un índice definido por el cociente entre la masa seca de la hoja por unidad área de la misma, cuyo valor es inverso al del *Specific leaf area* – *SLA* ($SLA=LMA^{-1}$) (Asner *et al.*, 2011) y equivalente al del DMC (Garnier y Navas, 2012). Es decir, el LMA se puede calcular como:

$$LMA = \frac{\text{Peso seco de la hoja}}{\text{Área de la hoja}} = \frac{W_d}{A} \left[\frac{g}{cm^2} \right]$$

El valor del peso seco (W_d) se obtendrá a partir del análisis del FMC (*Fuel Moisture Content*). El proceso consiste en secar las muestras de vegetación por el método del *Ovendry Weight*, que consta de pesar cierta cantidad de vegetación y luego someterla a un secado por 24 horas a 60°C. Luego, se pesará nuevamente la muestra para obtener el peso seco. Ahora bien, PROSPECT es un modelo de transferencia radiativa a nivel de hoja, por lo cual sus parámetros de entrada también lo son. Por ende, es necesario obtener el peso seco de una hoja, o bien, el peso seco de una aguja de pino. Para esto, se seleccionarán 10 agujas representativas de la muestra (las mismas que se indicaron con anterioridad para el cálculo del EWT de forma destructiva) y se pesarán en la balanza, en donde a dicho peso se le dividirá por 10 para obtener un peso promedio por aguja de pino. Lo siguiente consiste en lo que se dijo previamente del procesamiento de las imágenes que se le tomarán a las 10 agujas sobre una hoja blanca. Más información sobre el procesamiento se puede apreciar en el Anexo H. Lo anterior es debido a la complejidad de calcular el área de una hoja.

Como ya se dijo con anterioridad, la obtención del LMA es posible de calcular mediante modelos estadísticos (Féret *et al.*, 2011), pero resulta imposible con los instrumentos con los que se cuenta en la presente investigación, dado que se requeriría contar con un espectrómetro que abarque, por ejemplo, la región del infrarrojo de onda corta entre los 1.300 a 1.750 nm con el fin de poder utilizar el índice ND_{LMA} propuesto por Féret *et al.* (2011) y emplear una regresión polinomial, como se estudió en la Sección 2.3.4.1 (Leaf Mass per Area).

Al momento de contar con todos los parámetros, se procede a ingresar los datos a PROSPECT en <http://opticleaf.ipgp.fr/index.php?page=prospect> y el resultado será una tabla que contiene los valores de reflectancias entre los 400 – 2.500 nm, a una resolución de 1 nm.

Para entender el cómo varían los valores de reflectancia en función de los parámetros de entrada del modelo, es que se realizaron los gráficos presentes en la Figura 3.7. Se puede observar que variaciones en el parámetro de estructura interna de la hoja afectan a todo el espectro de reflexión comprendido entre los 400 – 2.500 nm, siendo, por lo tanto, un factor sumamente relevante a determinar, y pequeños errores afectarían, inclusive, la sección del SWIR, que es aquella que se hipotetiza es la porción del espectro con una mayor correlación con las variables asociadas a la calorimetría de los combustibles –para el análisis de gestión del riesgo en incendios forestales– por presentar las regiones espectrales de la absorción de agua, como se estudió en el Estado del Arte del presente proyecto.

3.4.2.2 Procedimiento experimental para el análisis espectral

Paso 1: Montaje del aparato

- a) Lo primero a realizar es montar el aparato experimental, es decir, conectar un extremo de la fibra óptica al espectrómetro y el otro extremo al *Probe Stand* (soporte RPS–SMA) que la sitúa

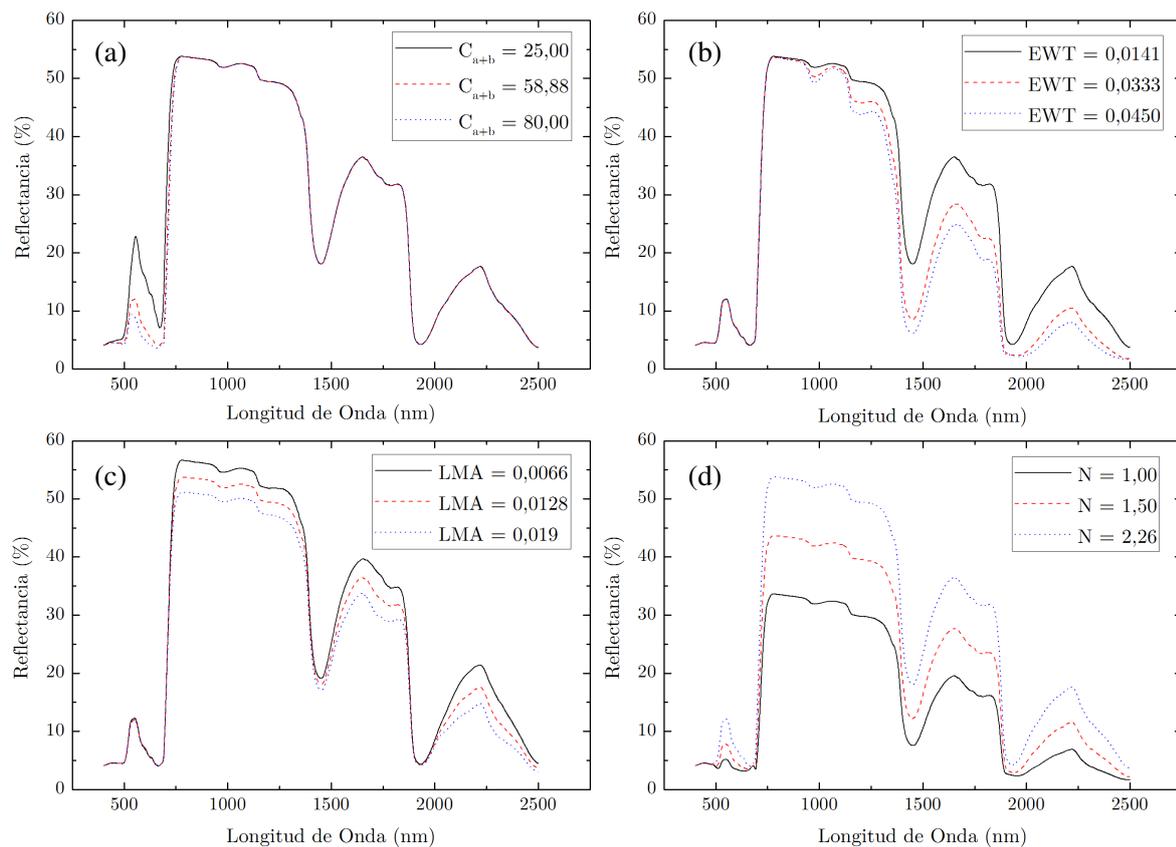


Figura 3.7: Variaciones en la reflectancia de la muestra # 68 (*ceteris paribus*) de la base de datos de LOPEX93 para (a) variaciones en la clorofila a y b (C_{a+b}), (b) variaciones en la cantidad de agua por unidad de área (EWT), (c) variaciones en la masa seca de la hoja por unidad de área (LMA) y (d) distintos valores en la estructura interna de la hoja (N).

Fuente: Elaboración propia.

a nadir con la muestra (90°), todo a partir de conectores SMA. La altura que se utilizará es de 60 mm, debido a que el ángulo de observación aproximado de la fibra óptica es de 25° , lo que implica que existe superficie suficiente para colocar la muestra en el soporte sin tener que incurrir a ruidos por información fuera de éste. Notar que se debe proteger los instrumentos de la luz solar (colocar el espectrómetro a la sombra).

- b) Conectar el espectrómetro al computador (vía USB). En este caso el computador a utilizar es un Apple Macbook Pro, que cuenta con las siguientes características: 16GB memoria RAM, procesador Intel i5 y disco de estado sólido (SSD).
- c) Luego de conectado, se debe abrir el programa *Ocean View* del fabricante del espectrómetro (Ocean Optics) y seleccionar la opción de medición de reflectancia.

Paso 2: Experiencia

Este paso se divide en dos partes, la calibración y los ensayos. En este proyecto se define una experiencia como la obtención de 5 espectros de reflexión para una determinada muestra. Es decir, una experiencia se compone de 5 sub-experiencias que, en promedio, determinarán el espectro de reflexión para la muestra bajo análisis. A continuación se determinará el procedimiento a seguir para cada uno de éstos.

Paso 2.1: Calibración

- a) La calibración consiste en la referencia del blanco y del fondo (negro o *background*). Para esto, luego de conectado el aparato y abierto el programa, se utiliza el estándar de referencia de reflectancia difusa del fabricante (WS-1) para calibrar la total reflectancia (100 %). Así, se debe colocar la referencia del blanco en donde iría la muestra y se debe revisar que en el programa se observe una línea horizontal ubicada en el 100 % en el eje de las coordenadas (reflectancia), que corresponde a la total reflectancia y luego continuar para calibrar el fondo. La calibración del *background* consiste en tapar el lente de la fibra óptica con un paño negro con el fin de simular una absorción total (0 %) de reflectancia, en donde el programa muestra una línea horizontal a lo largo del 0 % del eje de reflectancia (eje vertical).
- b) Luego se procede a los ensayos.

Paso 2.2: Ensayos

- a) Para cada experiencia se utilizará una masa aproximada de 10 gramos de agujas de pino radiata, que se pesarán y se guardarán en bolsas herméticas.
- b) Luego de una calibración, se coloca la muestra y se guarda el registro del espectro de reflexión analizado gracias al programa *Ocean View*. Se debe seleccionar un directorio para que se guarden los archivos así como un nombre al mismo. Los resultados se guardarán en un archivo ASCII (archivo de texto), con los valores de reflectancias a sus respectivas longitudes de onda.
- c) Luego de medir un espectro de reflexión para una determinada muestra, el aparato se calibra y se obtiene, nuevamente, el espectro de reflexión para la misma muestra. Dicho procedimiento se repetirá 5 veces por muestra, y al promedio de cada una de estas 5 sub-experiencia se le llama experiencia, que sería un valor promedio del espectro observado para esa muestra. Por ejemplo, si se realizan muestras de 3 pinos (3 experiencias), en total se obtendrán 5 espectros por muestra (sub-experiencias) i.e. 15 espectros en total.

3.4.3 Información Satelital

La mayor limitante radica en un calce de tiempos para la convergencia entre una buena imagen satelital (sin nubosidad) y un viaje a la reserva y laboratorio para el análisis de las muestras. Pero una vez que lo anterior se cumple, pues entonces se adquiere la imagen satelital del satélite Landsat 8 desde la plataforma GLOVIS (<http://glovis.usgs.gov/>) del USGS.

Lo siguiente consiste en el trabajo de la imagen para dejar los píxeles en valores de reflectancia y así poder trabajar con índices espectrales a partir de las bandas que el sensor OLI del satélite a utilizar cuenta. Dicho trabajo se llevará a cabo en el programa ENVI 5.3, en donde se realizará una calibración radiométrica para pasar los valores de los píxeles de DN a reflectancia y luego se utilizará la corrección atmosférica *Dark Subtraction* para obtener dichos valores de reflectancia a nivel de la superficie (para mayor información ver la [Sección 2.2.2](#)). Luego de esto, la imagen se encontrará con su información en valores de reflectancia y se puede proceder a calcular índices espectrales a través de una simple matemática de bandas.

Por otro lado, las imágenes provenientes del producto MCD15A2H del sensor MODIS de NASA correspondientes al producto LAI vienen calibradas y listas para utilizar. Es decir, al bajar la imagen y abrirla en programas como QGIS (que se utilizará para extraer la información requerida), éste automáticamente solicita al usuario la capa de imagen que desea estudiar, donde uno debe seleccionar “*Leaf Area Index*”. Luego, la imagen está lista y los píxeles vienen con los valores del LAI, en una dimensión de 500 × 500 metros.

4 | Resultados Experimentales

En el presente capítulo se darán a conocer los resultados obtenidos de la experimentación así como también un análisis de dichos resultados. Los contenidos y el orden que abarca el presente capítulo se puede apreciar en el esquema de la [Figura 4.1](#). El objetivo consiste en aplicar la metodología propuesta para evaluar la relación entre la información espectral a nivel de espectrometría y a nivel satelital, y evaluar la factibilidad de ésta para la obtención del L-FMC.

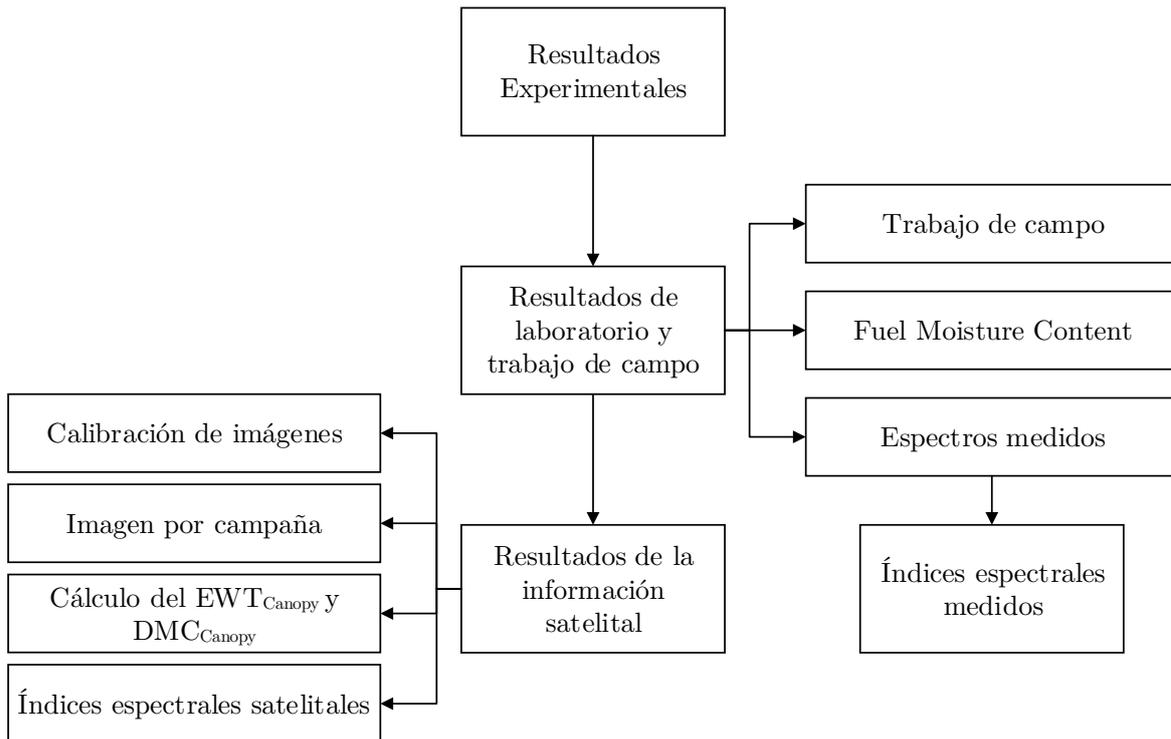


Figura 4.1: Esquema de los contenidos del capítulo Resultados Experimentales.

Fuente: Elaboración propia

4.1. Resultados de laboratorio y trabajo de campo

En esta sección se darán a conocer los resultados del estudio de la humedad de los combustibles, el trabajo de campo y los espectros medidos e índices espectrales a partir del uso del espectrómetro.

4.1.1 Trabajo de campo

Se realizaron tres viajes exitosos de trabajo de campo de un total de cinco. Lo anterior se debió, principalmente, a que hubo dos días que se trabajó y luego la imagen satelital no servía dado que había nubosidad, por ende nada de lo que se hizo en el día sirvió. Los días exitosos se detallarán como experiencias, y se pueden apreciar en la [Tabla 4.1](#).

Es importante destacar que en base a lo que se dijo con anterioridad (la dificultad de calzar la recolección de muestras con una buena imagen satelital) es que se creó una metodología basada en la conveniencia y en una eficiencia de los recursos. La metodología que se estableció fue que se iría a recolectar las muestras y trabajar en el laboratorio el día siguiente del paso del satélite. De esta

Tabla 4.1: Fechas de visitas de recolección de muestras más trabajo de laboratorio.

Experiencia	Fecha de visita
Experiencia 1	02 de Enero de 2017
Experiencia 2	18 de Enero de 2016
Experiencia 3	07 de Marzo de 2017

forma es posible revisar la imagen antes de ir a terreno y así no perder tiempo ni recursos. Si bien se recolectaron las muestras al día siguiente, la hora de recolección es la misma hora a la que pasó el satélite el día anterior, y ya se pudo observar en el [Estado del Arte](#) que las variaciones del FMC son diarias, por eso mismo es que se establece la metodología basada en la recolección a la misma hora del paso del satélite. Hubo muchas veces que se viajó a trabajar pensando que la imagen estaría buena (aún cuando se revisó el tiempo), pero la región de Valparaíso generalmente presenta bastante nubosidad por las mañanas, no así en el verano, donde se encontraron excelentes días y por ende muy buenas imágenes.

Por otro lado, es también importante conocer los puntos de muestreo. Para ubicarse espacialmente, es que se creó el mapa de la [Figura 4.2](#), con el fin de reconocer el bosque donde se recolectaron las muestras que se marcó como “Bosque de Muestreo”. Luego, la [Figura 4.3](#) representa los puntos de recolección en el “Bosque de muestreo” para cada experiencia, detallados en la descripción de la imagen. Es importante destacar que luego de recolectar muestras de un determinado pino, es que se contaron un mínimo de 40 pasos entre el próximo pino, de modo que así se evita que dos pinos estén contenidos en un mismo píxel de la imagen satelital (que es de 30×30 metros).

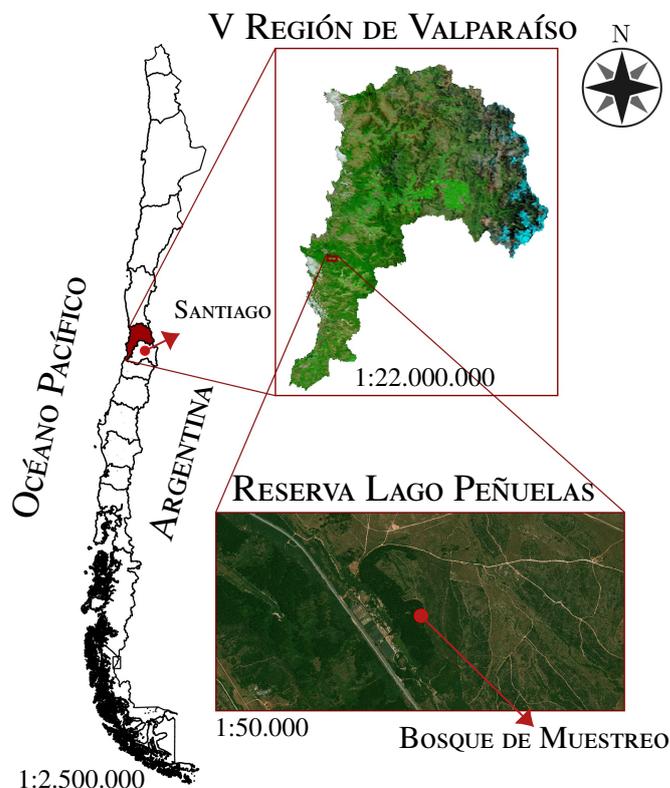


Figura 4.2: Mapa del bosque en la Reserva Lago Peñuelas donde se recolectaron las muestras.

Fuente: Elaboración propia.

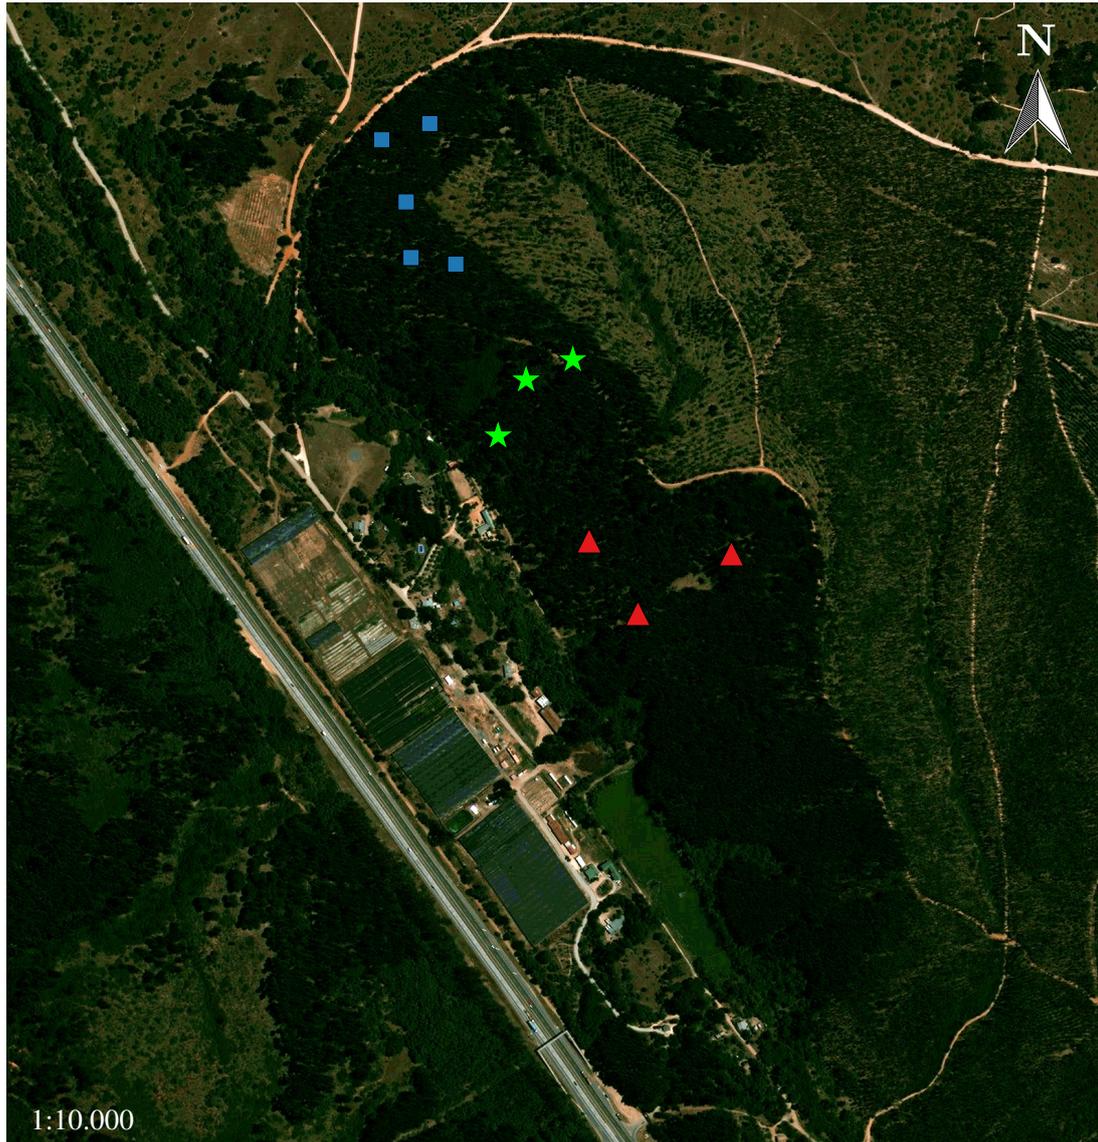


Figura 4.3: Mapa de los puntos de recolección en el “Bosque de Muestreo” de la Reserva Lago Peñuelas. Los triángulos rojos, estrellas verdes y cuadrados azules representan la ubicación de la recolección de muestras para la experiencia 1, 2 y 3, respectivamente.

Fuente: Elaboración propia.

4.1.2 Obtención del FMC

Para la obtención del FMC se empleó la técnica de la obtención del peso seco por medio del secado en horno (*Ovendry Weight*) a 60°C por 24 horas. Para cada muestra de pino P_i en la experiencia E_j (con $i = 1, 2, 3$ y $j = 1, 2, 3, 4, 5$), se obtuvo su correspondiente FMC. Para la obtención de sus pesos tanto fresco como seco, las muestras se masaron 5 veces, y el resultado del promedio de estas 5 mediciones es el que se utilizó. Para el peso fresco, se intentó utilizar 5 gramos de muestra. Los resultados se pueden apreciar en la [Tabla 4.2](#).

Es importante destacar en el cálculo del FMC, el “sub-cálculo” de ciertos parámetros para 10 agujas de pinos con el objetivo de determinar el peso fresco para 1 aguja de pino representativa de cada muestra, así como el valor del área de éstas, que corresponden a valores que se utilizarán más adelante

Tabla 4.2: Resultados del FMC con la técnica del *Ovendry Weight*.

Experiencia	Muestra	Peso fresco [gr]	Peso seco [gr]	FMC
E1	P1	5,011	2,020	148,07 %
	P2	5,012	1,950	157,05 %
	P3	5,002	2,045	144,58 %
E2	P1	5,006	2,075	141,27 %
	P2	4,994	2,062	142,17 %
	P3	4,999	2,117	136,15 %
E3	P1	4,992	2,123	135,14 %
	P2	4,985	2,112	136,02 %
	P3	5,000	2,135	134,21 %
	P4	5,021	2,260	122,19 %
	P5	5,013	2,134	134,89 %

para calcular variables como el LMA (*Leaf Mass per Area*), el EWT (*Equivalent Water Thickness*) y el DMC (*Dry Matter Content*). Para esto, al momento de escoger los 5 gramos de muestra para el FMC “total” de la muestra, se escogieron 10 agujas de pino representativas de la muestra total (de los 5 gramos), que si bien fueron sacadas aleatoriamente de la muestra completa, se intentó que fuesen lo más representativas posibles en cuanto al tamaño de éstas. Luego, las 10 agujas se posicionaron separadas sobre una hoja blanca con una regla en la parte inferior, en donde se procedió a tomar una fotografía con el celular para su posterior procesamiento en el computador. El detalle del proceso llevado a cabo para el procesamiento de las imágenes, con el fin de obtener el área de una aguja de pino promedio por muestra, se puede apreciar en el [Anexo H](#), la gráfica que representa los valores medios y la desviación estándar de las áreas por muestra se pueden apreciar en la [Figura 4.4](#).

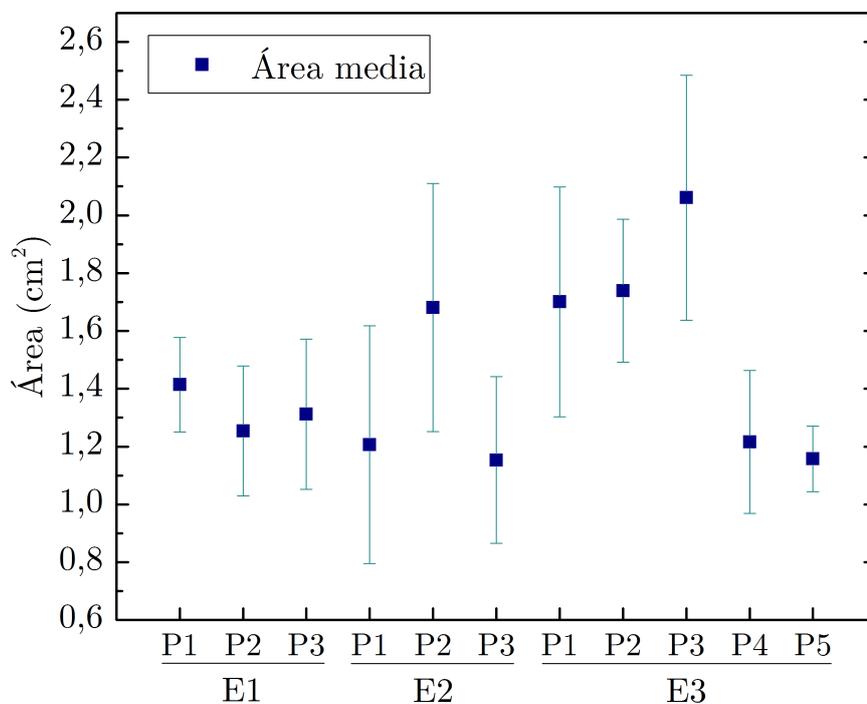


Figura 4.4: Gráfico de los valores medios de las áreas de agujas de pino. Las barras de error representan la desviación estándar de las mediciones para las 10 agujas de cada muestra.

Fuente: Elaboración propia.

Más tarde, las 10 agujas se masaron y se obtuvo un peso promedio por cada aguja. Como estas 10 agujas forman parte del total del FMC por cada muestra P_i , es que al momento de secarlas en el horno, se amoldó trozos de papel de aluminio para separar en cada una de estas la muestra, por ejemplo, P1, que contenía por un lado las 10 agujas mencionadas con anterioridad y, en el otro lado, el resto de agujas que en total sumaban el FMC para la muestra P1, tal cual como se puede apreciar en la [Figura 4.5](#).



Figura 4.5: Imagen de las muestras, correspondiente a la experiencia 3, previo al secado en el horno. Se puede apreciar por bandeja de aluminio, la separación para la obtención del peso seco de las 10 agujas, así como del total de la muestra. De esta forma, en cada pocillo moldeado de papel de aluminio se encuentra un total de, aproximadamente, 5 gramos de agujas de pino, que contemplan, a su vez y separadamente, las 10 agujas de pino.

Fuente: Elaboración propia.

Luego del secado en el horno, se masó, primeramente, las 10 agujas de pino y luego se mezcló con el resto para así obtener el peso seco total de cada muestra P_i , para luego obtener el FMC. Los resultados del trabajo de laboratorio enfocado en las 10 agujas se puede apreciar en la [Tabla 4.3](#). El objetivo de lo anterior es obtener un peso fresco y seco en conjunto con el área para solo 1 aguja de pino, que vendría siendo una aguja de pino “representativa” de la muestra recolectada. Esto se utilizará más adelante para el cálculo de las variables implicadas en los parámetros de entrada de PROSPECT.

Es importante destacar que el valor del FMC es constante para todo un árbol (en éste caso brotes terminales de vegetación i.e. agujas de pino radiata). Por lo tanto, en estricto rigor se debiese cumplir la identidad correspondiente a la ecuación (4.1).

$$\text{FMC} = \underbrace{\frac{W_f - W_d}{W_d}}_{(a)} = \underbrace{\frac{\frac{W_f - W_d}{A}}{\frac{W_d}{A}}}_{(b)} = \frac{\text{EWT}_{\text{Leaf}}}{\text{DMC}_{\text{Leaf}}} \quad (4.1)$$

Tabla 4.3: Resultados para el análisis de 1 aguja de pino. W_f corresponde al peso fresco (*fresh weight*) y W_d corresponde al peso seco (*dry weight*). Estos resultados son relevantes para el cálculo de algunos parámetros de entrada para el modelo de transferencia radiativa PROSPECT.

Exp.	Muestra	W_f [gr] (10 agujas)	W_f [gr] (1 aguja)	W_d [gr] (10 agujas)	W_d [gr] (1 aguja)	Área 1 aguja [cm ²]
1	P1	0,706	0,071	0,297	0,030	1,141
	P2	0,521	0,052	0,205	0,021	1,254
	P3	0,570	0,057	0,239	0,024	1,312
2	P1	0,706	0,071	0,297	0,030	1,206
	P2	0,521	0,052	0,205	0,021	1,681
	P3	0,570	0,057	0,239	0,024	1,153
3	P1	0,472	0,047	0,202	0,020	1,701
	P2	0,526	0,053	0,219	0,022	1,739
	P3	0,703	0,070	0,303	0,030	2,155
	P4	0,482	0,048	0,216	0,022	1,217
	P5	0,528	0,053	0,225	0,023	1,158

Pero en la práctica esto no se cumple en su totalidad. Es decir, al momento de medir el FMC desde el peso fresco (W_f) y peso seco (W_d), la parte (a) de la ecuación (4.1), existe un valor que se le llamará FMC medido (FMC_{Medido}), que corresponde a aquel valor del FMC obtenido de la muestra total. En tanto, si el FMC se mide desde el otro lado de la igualdad i.e. el cociente entre el EWT_{Leaf} y DMC_{Leaf} , no se obtiene el mismo valor del FMC_{Medido} (parte (b) de la ecuación (4.1)). Lo anterior, se debe a que si se obtiene el FMC a partir de la parte (b) de la ecuación (4.1), pues entonces se mide el FMC en términos de la metodología que se empleó para analizar el peso seco y fresco para una aguja de pino. Existen ciertos errores asociados a esta metodología, dado que la representatividad de dicha aguja en torno a la muestra presenta algunas variaciones del FMC. De esta forma, la diferencia entre los valores que se determinaron como FMC_{Medido} y $FMC_{Metodología}$ (a partir de la parte (b) de la ecuación (4.1)), con su correspondiente error experimental, se puede apreciar en la [Tabla 4.4](#).

Tabla 4.4: FMC medido vs FMC de la metodología empleada.

FMC_{Medido}	$FMC_{Metodología}$	Error Experimental
148,07 %	137,82 %	6,92 %
157,05 %	154,15 %	1,85 %
144,58 %	138,63 %	4,11 %
141,27 %	132,00 %	6,56 %
142,17 %	135,42 %	4,75 %
136,15 %	131,36 %	3,51 %
135,14 %	133,66 %	1,09 %
136,02 %	140,18 %	-3,06 %
134,21 %	131,90 %	1,72 %
122,19 %	123,30 %	-0,91 %
134,89 %	134,67 %	0,17 %

Entiéndase por Error Experimental a: $(FMC_{Medido} - FMC_{Metodología}) / FMC_{Medido}$. Luego, la media del error experimental (que se dejó en valor absoluto) equivale a 3,15 %. De esta forma, se genera una necesidad de entender la relación entre el FMC_{Medido} y el cociente entre el EWT_{Leaf} y DMC_{Leaf}

($FMC_{\text{Metodología}}$). Dicha relación se puede apreciar en la [Figura 4.6](#).

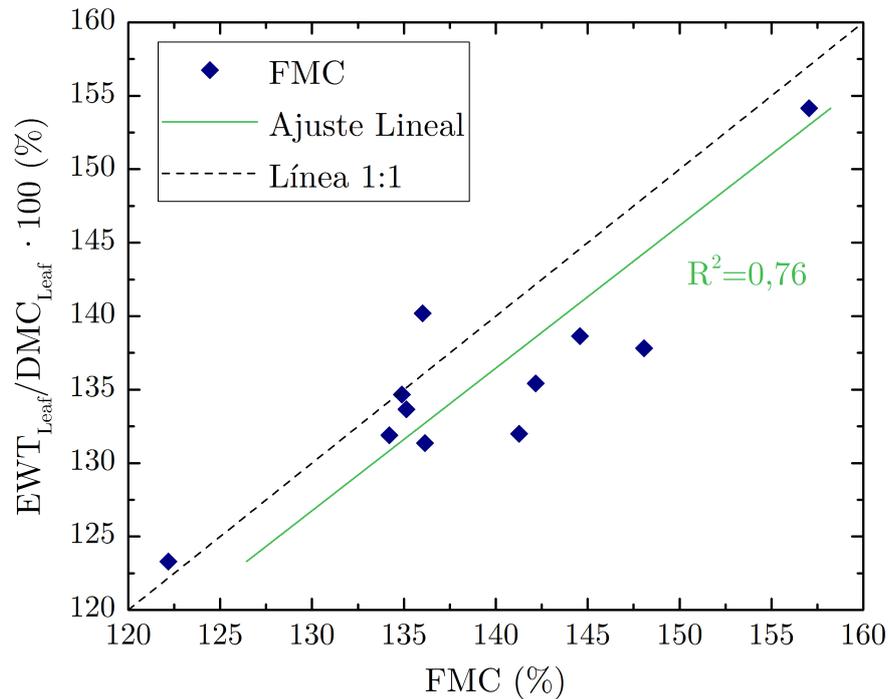


Figura 4.6: FMC medido en laboratorio versus el FMC metodológico (cociente entre EWT_{Leaf} y DMC_{Leaf}).

Fuente: Elaboración propia.

A partir de la [Figura 4.6](#), se puede apreciar que el FMC busca tender a un comportamiento lineal. El coeficiente de correlación no es lo suficientemente elevado como se pensó, pero aún así es importante generar un modelo a partir de la regresión, debido a que se estima que los resultados que vienen más adelante tendrán una mejor correlación con el $FMC_{\text{Metodología}}$ que con el FMC_{Medido} , puesto que cuando se aplique el concepto del EWT y DMC a nivel del dosel (para la información satelital), los valores que se utilizan son del EWT y DMC a nivel de hoja, y no el del FMC. En tanto, cabe destacar que, en general, los puntos se ubican por debajo de la línea 1:1, lo que implica que la metodología del cociente entre el EWT_{Leaf} y DMC_{Leaf} tiende a subestimar los valores del FMC para toda la muestra.

De esta forma, es interesante comprender las diferencias a partir de ambos resultados para el FMC. Para esto, se elaboró un gráfico de cajas que resume los resultados y rangos de una forma visual. Dicho diagrama se puede apreciar en la [Figura 4.7](#).

De esta forma, a partir del diagrama de cajas de la [Figura 4.7](#), es posible realizar una serie de análisis. Primero, el rango de valores para el FMC_{Medido} varía entre 122,19 %–157,05 %. En tanto, para el caso del $FMC_{\text{Metodología}}$ i.e. cociente entre EWT_{Leaf} y DMC_{Leaf} , el rango de valores es entre 123,30 %–154,15 %. Las variaciones entre el rango no son sustanciales, y el $FMC_{\text{Metodología}}$ no sobrepasa los rangos medidos del FMC. Por otro lado, la media de los datos para el FMC_{Medido} se concentra en 139,25 %, mientras que en el $FMC_{\text{Metodología}}$ se ubica a los 135,74 %. El grueso de los datos (50 %) se concentra, para el FMC_{Medido} , desde los 134,89 % hasta los 144,57 %, mientras que en el caso del $FMC_{\text{Metodología}}$ la concentración del 50 % de los datos es mayor, donde la variación de estos va desde los 131,90 % hasta los 138,63 %, que se puede apreciar visualmente por el tamaño de las cajas en ambos casos. Luego, la mediana de los datos, en ambos casos, tiende hacia el primer cuartil, por lo que los datos se concentran hacia la parte inferior del cajón. Por último, se puede destacar que para el caso del $FMC_{\text{Metodología}}$ existe un dato atípico máximo. Esto ocurre debido a que el valor máximo permitido

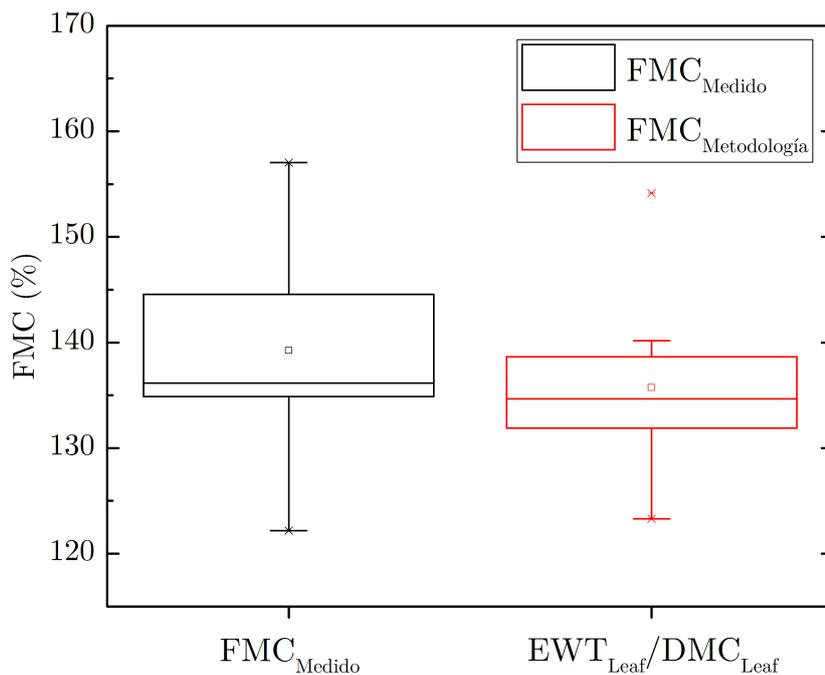


Figura 4.7: Diagrama de cajas para una comparación visual entre el FMC_{Medido} y el $FMC_{Metodología}$.
Fuente: Elaboración propia.

por el diagrama es el tercer cuartil más 1,5 veces la diferencia entre el tercer y primer cuartil, el cual equivale a 148,73 %, que claramente es menor al máximo de la muestra que equivale a 154,15 %. De esta forma, cualquier valor, para el caso del $FMC_{Metodología}$, sobre 148,73 % será un dato atípico. El extremo superior llega solo hasta el 140,18 % debido a que es el segundo mayor dato obtenido para valores del $FMC_{Metodología}$.

El modelo para estimar el FMC_{Medido} a partir del cociente entre el EWT_{Leaf} y DMC_{Leaf} se resume en la ecuación (4.2).

$$FMC_{Medido} = 103,01969 \cdot \frac{EWT_{Leaf}}{DMC_{Leaf}} - 0,58665 \quad (4.2)$$

En tanto, el error medio cuadrático del modelo anteriormente nombrado ($RMSE_{Metodología}$) se expresa y equivale a:

$$RMSE_{Metodología} = \sqrt{\frac{1}{n} \sum_{i=1}^n (FMC_{Medido} - FMC_{Metodología})^2} = 5,47 \% \quad (4.3)$$

4.1.3 Espectros medidos

En la presente sección se presentarán los espectros medidos a partir del uso del espectrómetro. También, se mostrarán los espectros de cada experiencia en un solo gráfico para mostrar las variaciones entre muestras de una misma experiencia, pero diferentes pinos. Por otro lado, se realizará una breve descripción de algunos índices espectrales que se pueden obtener en el rango espectral que otorga el espectrómetro (ver la [Sección 4.1.3.1 – Índices obtenidos a partir del espectro medido](#)).

Para comprender las gráficas que se presentarán, es importante entender que las experiencias de denotarán por la letra Ei con i equivalente al número de experiencia, donde $i \in \{1, 2, 3\}$, caso igual para el pino Pj , con j correspondiente al número de pino de la respectiva experiencia, donde $j \in \{1, 2, 3, 4, 5\}$.

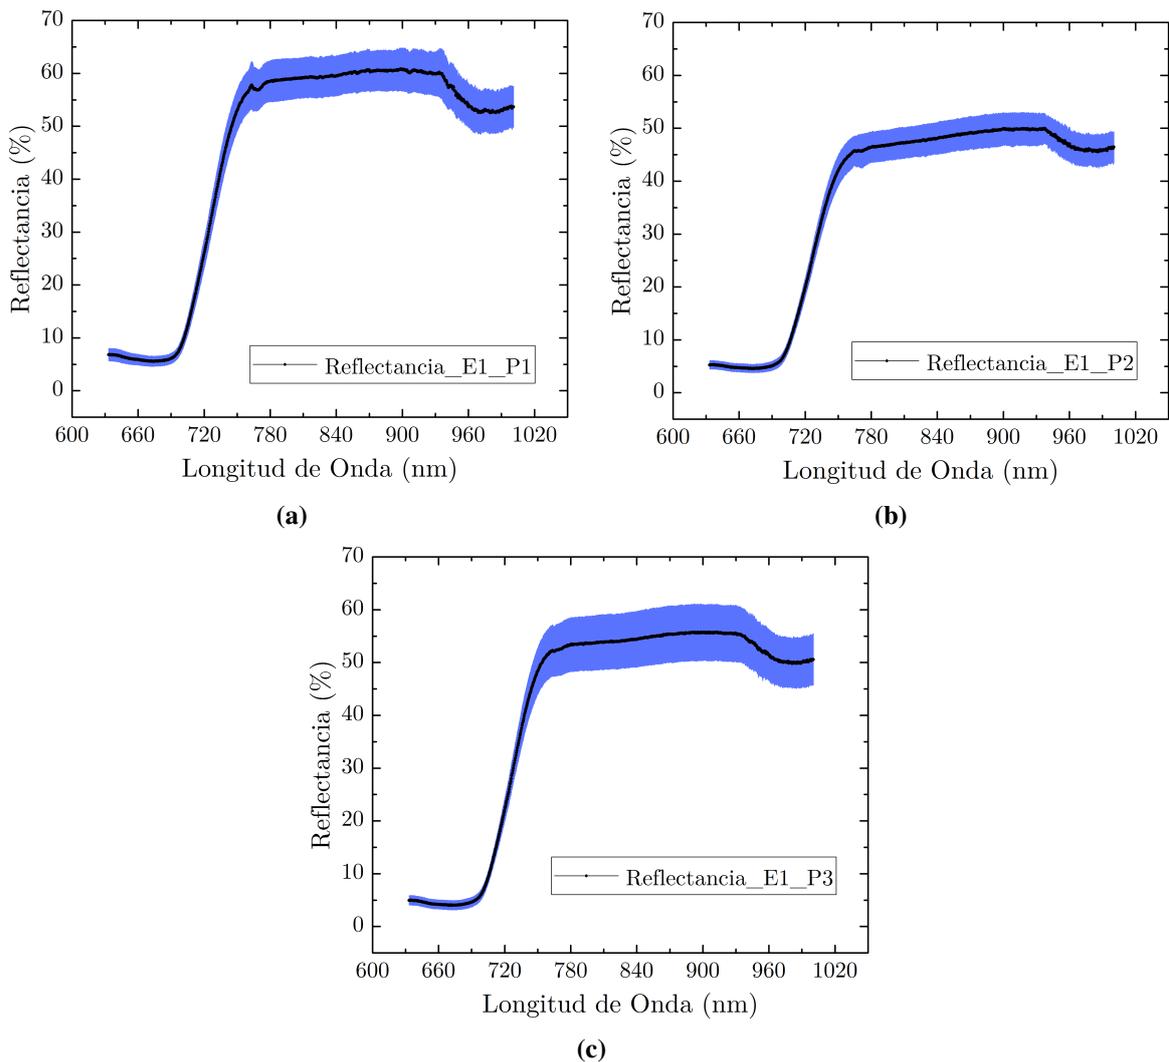


Figura 4.8: Gráficos del espectro medido para la experiencia 1, donde (a), (b) y (c) corresponden a la reflectancia del pino 1, 2, y 3, respectivamente. En cada uno de los gráficos se puede apreciar en color azul la desviación estándar de los 5 espectros que se analizaron para dejar solo el promedio (línea negra).

Fuente: Elaboración propia.

De las Figuras 4.8, 4.9 y 4.10 se puede apreciar que las curvas obtenidas presentan, en su porción del espectro, la característica de vegetación viva. El *peak* que se puede observar entre los 700 y 750 nm es lo que se conoce como la curva de *Red Edge*. Es justo la porción del espectro en donde cambia

el análisis de la pigmentación de la hoja entre los, aproximadamente, 400 – 700 nm, que se caracteriza por una reflectividad bajo el 10 %, al análisis de la estructura interna, que generalmente varía entre los 750 – 1.300 nm y, para éste experimento, presentó variaciones entre los 30 a 60 % de reflectividad. Por otro lado, si bien el rango espectral que entrega el espectrómetro va desde los 650 – 1.100 nm, es importante destacar que sobre los 1.000 nm se apreció bastante ruido en los datos, por lo que se dejaron los valores de reflectancia hasta los 1.000 nm, para todos los casos.

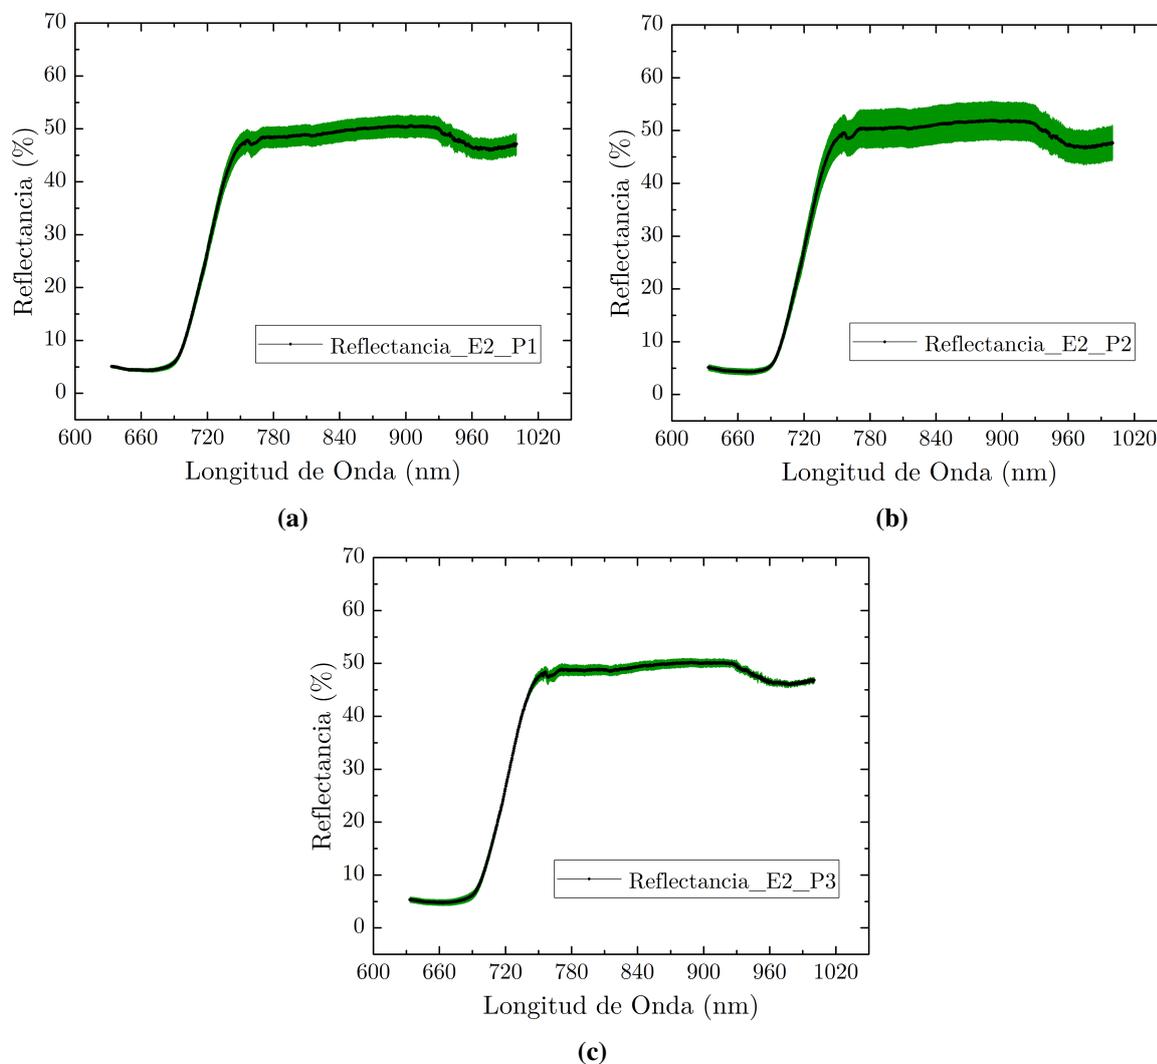


Figura 4.9: Gráficos del espectro medido para la experiencia 2, donde (a), (b) y (c) corresponden a la reflectancia del pino 1, 2, y 3, respectivamente. En cada uno de los gráficos se puede apreciar en color verde la desviación estándar de los 5 espectros que se analizaron para dejar solo el promedio (línea negra).

Fuente: Elaboración propia.

Observar que las zonas fuera de las curvas (en colores) representan las barras de errores (de la desviación estándar de las “sub-experiencias” i.e. los 5 espectros medidos que se promediaron para dejar uno solo) pero, dada la cantidad de datos, resulta más interesante observarlo mediante una especie de “área de error”. El rango es variable para todas las mediciones, pero es curioso el cómo pueden variar los datos para una misma experiencia con no más de 10 minutos para un total de 5 mediciones del espectro. Casos con alto error se presentan, por ejemplo, en las figuras 4.8a, 4.8c y 4.9b. No está demás observar que las variaciones se presentaron, mayoritariamente, en la zona correspondiente a la estructura interna, en lo que sería la zona del infrarrojo cercano (*NIR*).

A modo de resumen para los espectros medidos, se presentan los gráficos que contienen las curvas de

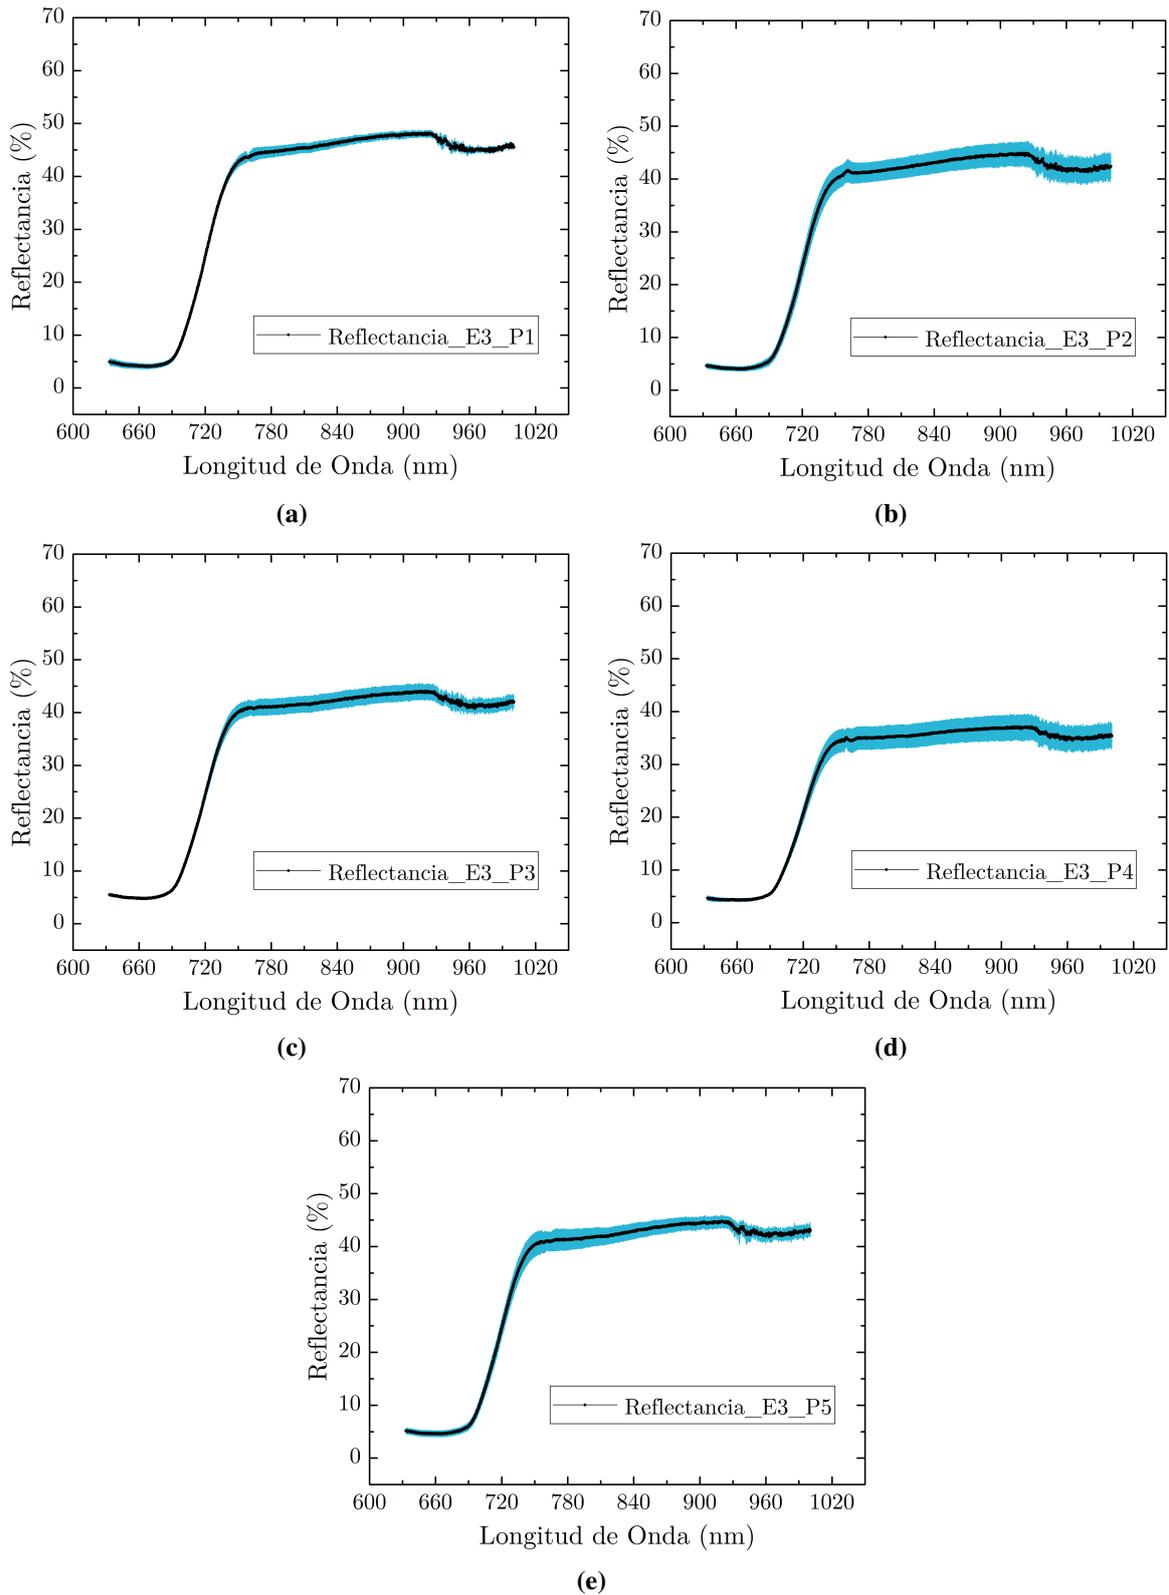
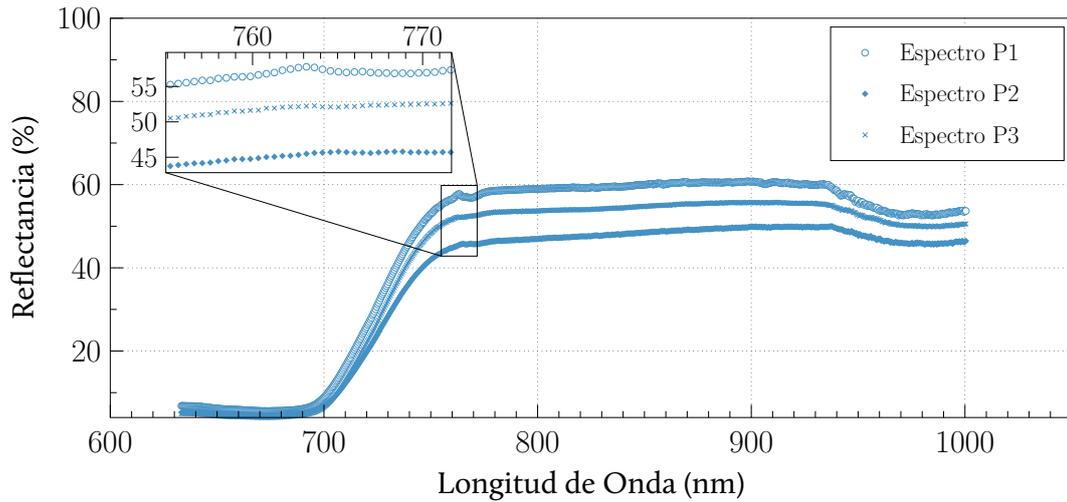


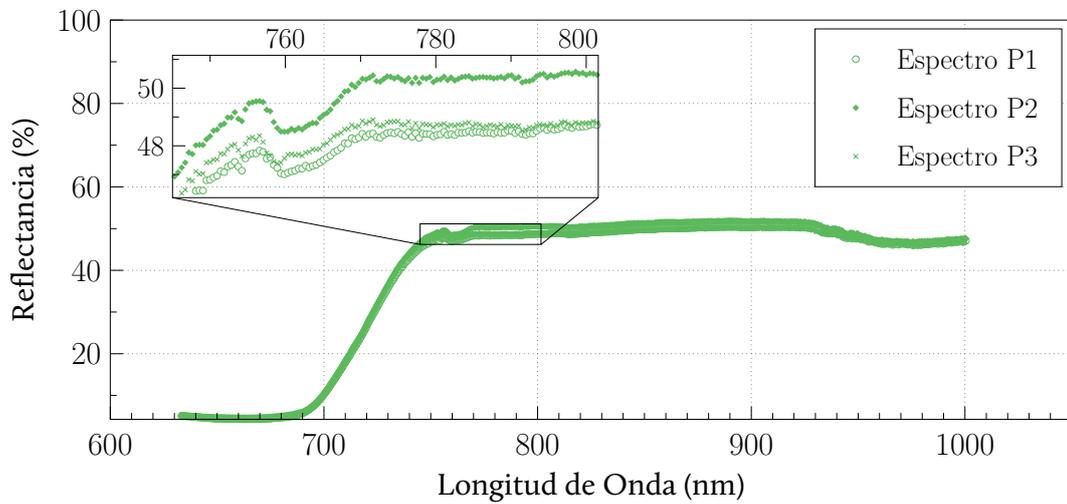
Figura 4.10: Gráficos del espectro medido para la experiencia 3, donde (a), (b), (c), (d) y (e) corresponden a la reflectancia del pino 1, 2, 3, 4 y 5, respectivamente. En cada uno de los gráficos se puede apreciar en color celeste la desviación estándar de los 5 espectros que se analizaron para dejar solo el promedio (línea negra).

Fuente: Elaboración propia.

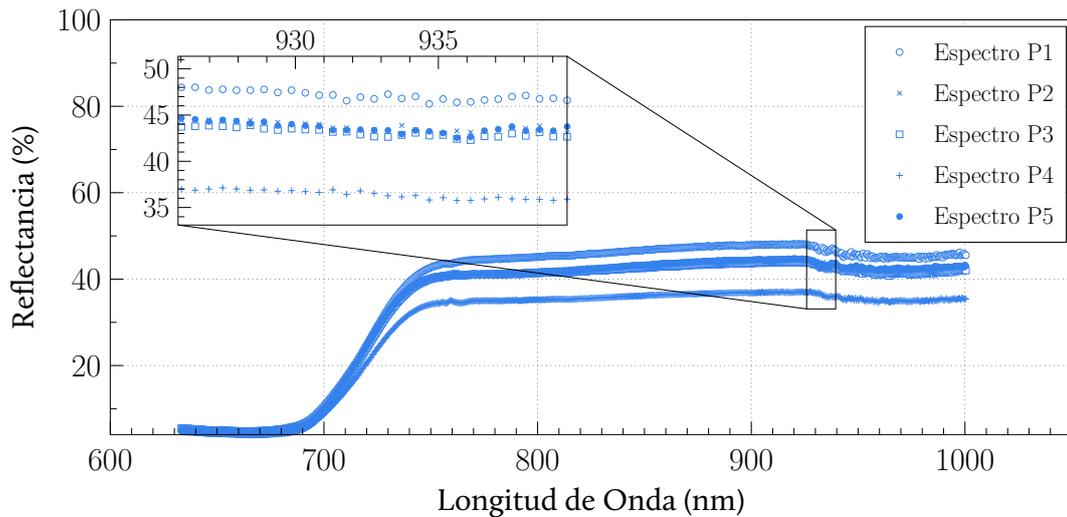
todos los espectros por experiencia realizada, que se pueden apreciar en la [Figura 4.11](#).



(a)



(b)



(c)

Figura 4.11: Gráficos resumen de los espectro medidos para todas las experiencias, donde (a), (b), (c) corresponden a las curvas del espectro medido de las experiencias 1, 2 y 3, respectivamente.

Fuente: Elaboración propia.

4.1.3.1 Índices obtenidos a partir del espectro medido

Existen una serie de índices espectrales para calcular, indirectamente, variables tanto físicas como fotosintéticas a partir de un espectro de reflexión, como ya se estudió en la Sección 2.2.4 (Índices espectrales). Pero existe una limitante para este caso, y es el rango espectral con el que se cuenta. De esta forma, algunos índices que pueden ser calculados son aquellos que se utilizarán para realizar la simulación en PROSPECT (para obtener variables como la clorofila y carotenoides – Índice de Gitelson) y otros que se encontraron en la literatura. Éstos se pueden observar en la Tabla 4.5.

Índice	Fórmula	Autor
Índice de Gitelson 1 (<i>I.G.1</i>)	$\frac{\rho_{775}}{\rho_{718}} - 1$	Gitelson <i>et al.</i> (2003)
Water Index (<i>WI</i>)	$\frac{\rho_{900}}{\rho_{970}}$	Peñuelas <i>et al.</i> (1997)
NDVI	$\frac{\rho_{850} - \rho_{680}}{\rho_{850} + \rho_{680}}$	Rouse <i>et al.</i> (1973)
mSR-like	$\frac{\rho_{780} - \rho_{710}}{\rho_{780} - \rho_{680}}$	Datt (1999b)
Índice de Gitelson 2 (<i>I.G.2</i>)	$\frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}}$	Gitelson y Merzlyak (1994)

Tabla 4.5: Algunos índices espectrales que se pueden calcular a partir de la información obtenida por el espectrómetro. Donde ρ_{λ} corresponde a los valores de reflectancia en la longitud de onda “ λ ” (*nm*).

Fuente: Elaboración propia.

Los índices de Gitelson (ambos) y el índice mSR-like se utilizan para relacionar información espectral de reflectancia con el contenido fotosintético de la vegetación (clorofila a+b – C_{a+b} – y carotenoides – C_{car}). Por otro lado, el *Water Index* se ha utilizado para relacionar la cantidad de agua presente en la vegetación i.e. EWT, mientras que el NDVI se ha empleado para determinar la vigorosidad de la vegetación.

Un análisis acabado para éstos datos no es relevante si no se puede comparar. Es debido a lo anterior que los resultados se analizan en la Sección 5.3.2 (Capítulo 5) en conjunto con los resultados de los mismos índices pero a partir del espectro simulado.

4.2. Información satelital

En la presente sección se darán a conocer los resultados asociados a la calibración radiométrica y atmosférica de las imágenes satelitales, así como también las imágenes por campaña de la zona bajo análisis y una serie de índices espectrales que se obtendrán a partir de éstas. Las imágenes Landsat 8 que se utilizarán son las correspondientes al *tile* que contempla los valores de *path*=233 y *row*=83, en las cuales se puede observar la mayor parte de la V región de Valparaíso, partes de la región Metropolitana y de la VI región del Libertador Bernardo O'Higgins. Las imágenes satelitales utilizadas por cada experiencia se detallan en la [Tabla 4.6](#)

Tabla 4.6: Imágenes Landsat 8 utilizadas por cada experiencia. En los 3 dígitos antes de "LGN" se pueden apreciar los número correspondientes al día juliano, donde el día 1 corresponde al primero de enero, el día 17 al 17 de enero y el día 65 al 6 de marzo de 2017.

Experiencia	Fecha	Imagen
E1	01-ene-17	LC82330832017001LGN00
E2	17-ene-17	LC82330832017017LGN00
E3	06-mar-17	LC82330832017065LGN00

4.2.1 Calibración

Hoy en día, programas computacionales como ENVI, que es el que se utilizó para procesar las imágenes en el presente proyecto, realizan el trabajo de la calibración de forma muy eficiente. Cada imagen satelital viene con un archivo de texto (.txt) que es el metadato de la imagen i.e. el archivo que trae toda la información de la imagen. Al momento de abrir la imagen en el programa, ésta opción debe ser a través del archivo metadatos. Luego, el proceso es bastante simple. Para el presente trabajo solo se calibrará, como se dijo con anterioridad, la radiometría de la imagen así como el ruido atmosférico. La radiometría se utiliza para dejar los valores de los píxeles en reflectancia (con valores entre 0 y 1) al nivel TOA (*top of atmosphere* – techo de la atmósfera). Luego, la calibración atmosférica, que se hará a partir de la metodología del *Dark Subtraction*, lleva dichos valores al nivel del suelo, corrigiendo algunos posibles errores atmosféricos. La verificación de resultados es sumamente relevante, por eso luego de cada calibración se revisan los estadísticos de la imagen, donde se asegura que los valores de la imagen estén entre 0 y 1 (ver [Figura 4.12](#)). No es anormal que existan algunos errores en estos datos y encontrar ciertos casos atípicos en donde se pueden apreciar valores bajo 0 o mayor 1. Generalmente, los valores anteriores se da por lugares en donde puede haber presencia de nieve (donde la reflectancia es total i.e. igual a la unidad, como, por ejemplo, en la cordillera) o datos anormales por relaves mineros, entre otros.

Luego de calibrar una imagen, se procede, con el uso de un archivo vectorial, a cortar la imagen que contiene las 7 bandas del canal multispectral del sensor OLI, reducido el área de la imagen a la zona bajo análisis (la Reserva Lago Peñuelas).

4.2.2 Imagen por campaña

La imagen satelital correspondiente a la experiencia 1 se puede apreciar en la [Figura 4.13](#). Las imágenes que se aprecian en dicha figura se ajustaron para dejar la imagen en color real (RGB) (Banda 4, Banda 3 y Banda 2), falso color infrarrojo (Banda 5, Banda 4, Banda 3) y, por último, se calibró la imagen para dejarla con los valores del *Normalized Difference Vegetation Index* (NDVI), cuya escala de valores se aprecia al costado de la misma. Las imágenes correspondientes a la experiencia 2 y 3 se pueden apreciar en el [Anexo I](#), siendo éstas la [Figura I.1](#) y [Figura I.2](#), respectivamente.

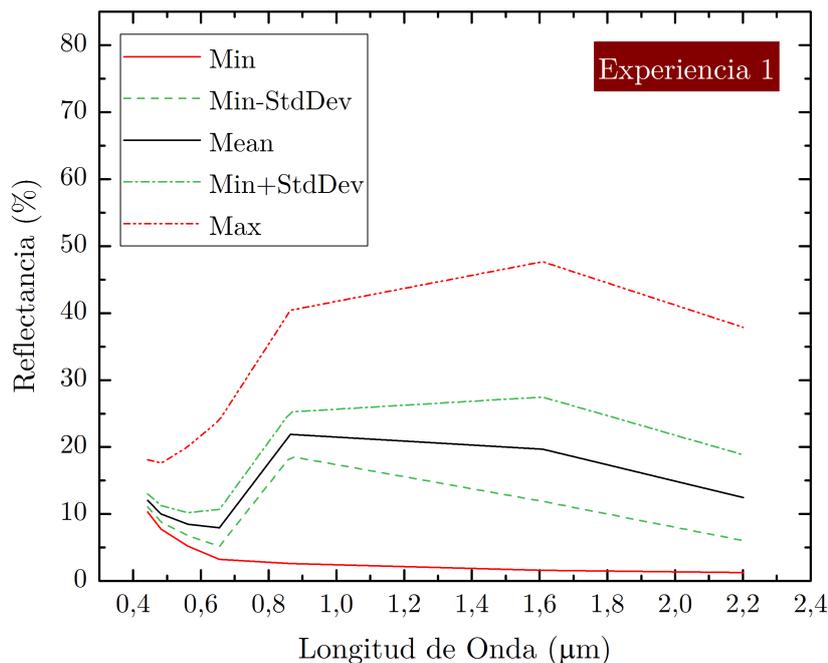


Figura 4.12: Ejemplo de la estadística de la imagen satelital correspondiente a la experiencia 1. Corresponde a las estadísticas asociadas al recorte de la imagen centrada en el área de estudio. Se pueden apreciar valores de reflectancia ρ entre $0 < \rho < 0,5$.

Fuente: Elaboración propia.

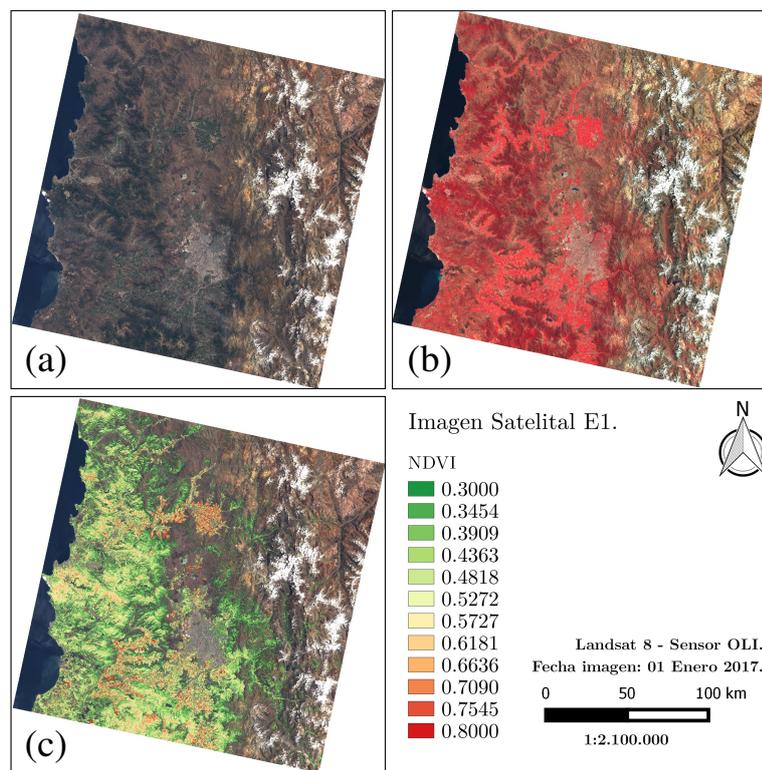


Figura 4.13: Imagen satelital correspondiente a la experiencia 1. (a) corresponde a la imagen en color real (RGB), (b) corresponde a la imagen en falso color (infrarrojo) y (c) presenta el NDVI para la imagen, donde valores más cercanos a 1 (más rojos) implican vegetación con mayor vigorosidad.

Fuente: Elaboración propia.

A modo de ejemplo, si se realiza un aumento a la zona bajo análisis para la experiencia 1, se tiene como resultado la imagen presente en la [Figura 4.14](#). En dicha imagen es posible notar los puntos en donde se realizaron las muestras para dicha experiencia, así como también una segunda imagen que contiene la calibración de la misma en valores del NDVI. De esta forma, se puede apreciar que el bosque de muestreo presenta altos valores de NDVI, por lo que se puede establecer que la zona presenta vegetación vigorosa.

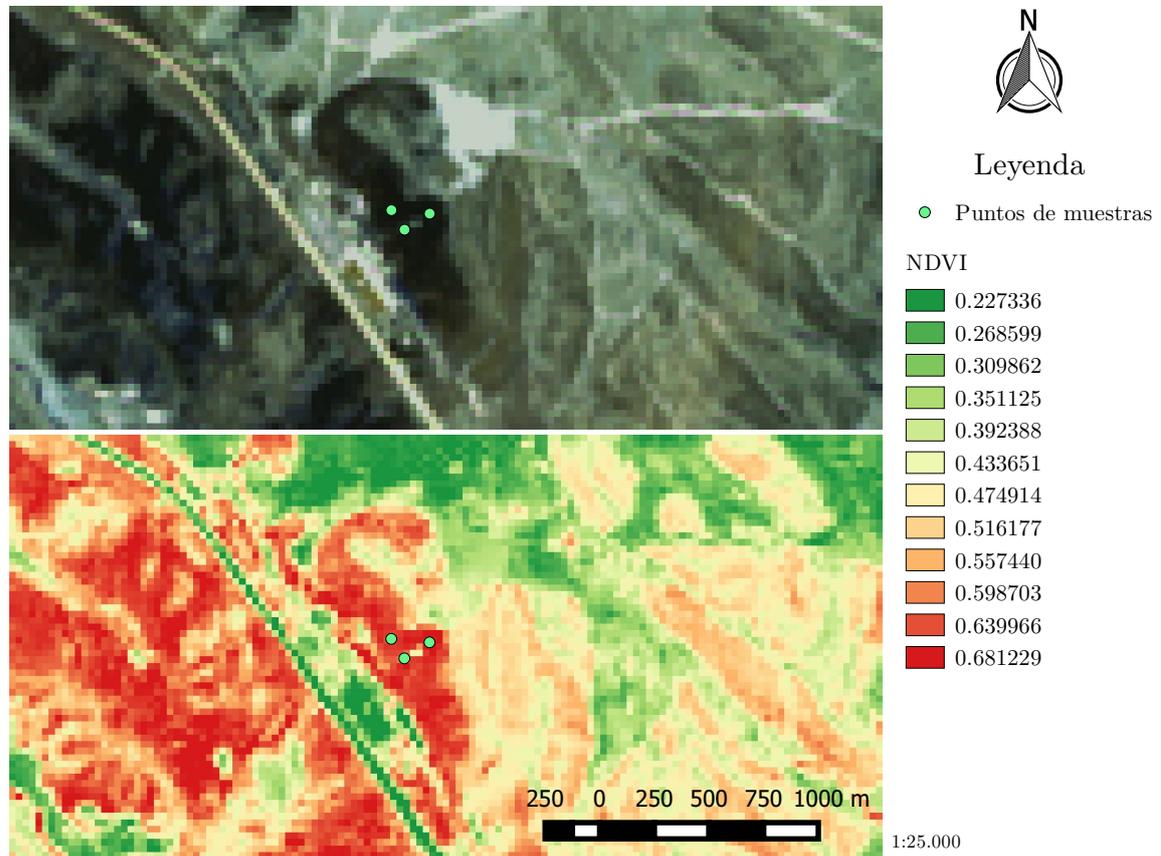


Figura 4.14: NDVI para la experiencia 1. La imagen también incluye los puntos de recolección de muestras para dicha experiencia. La imagen superior corresponde a la imagen calibrada, y la de abajo a la misma imagen, pero se le aplicó matemática de bandas para dejarla en valores de NDVI.

Fuente: Elaboración propia.

4.2.3 Cálculo del EWT y DMC a nivel del dosel

El EWT y DMC medido a nivel de hoja de nada sirven para ser estimados, indirectamente, a partir de información satelital, y es ahí donde entra el concepto del LAI. Así, el EWT_{Leaf} y DMC_{Leaf} se pueden multiplicar por dicho parámetro biofísico con el fin de obtener el EWT y DMC a nivel del dosel (EWT_{Canopy} y DMC_{Canopy}).

De esta forma, si se expande la ecuación (4.1) con el parámetro LAI, se tiene que:

$$FMC = \frac{W_f - W_d}{W_d} = \frac{\frac{W_f - W_d}{A}}{\frac{W_d}{A}} = \frac{EWT_{\text{Leaf}}}{DMC_{\text{Leaf}}} = \frac{EWT_{\text{Leaf}} \cdot LAI}{DMC_{\text{Leaf}} \cdot LAI} = \frac{EWT_{\text{Canopy}}}{DMC_{\text{Canopy}}} \quad (4.4)$$

De donde se obtiene que:

$$EWT_{\text{Canopy}} = EWT_{\text{Leaf}} \cdot \text{LAI} \quad (4.5)$$

$$\text{DMC}_{\text{Canopy}} = \text{DMC}_{\text{Leaf}} \cdot \text{LAI} \quad (4.6)$$

Es importante destacar que los valores del LAI no se obtuvieron experimentalmente, dado que resulta bastante complejo si no se cuenta con los instrumentos necesarios (ver Sección 2.3.1 para más información). De esta forma, como se explicó al comienzo del presente capítulo, el LAI se obtuvo a partir de imágenes del sensor MODIS de NASA, específicamente el producto MCD15A2H. Las descargas de las imágenes se realizaron a través de la plataforma REVERB ECHO de NASA.¹ Cabe mencionar que, para todas las experiencias, el *tile* (escena) correspondiente para toda la zona de estudio es el h12v12 (horizontal 12 y vertical 12). Luego, estas imágenes se abrieron en el programa QGIS 2.12.3, se seleccionó la capa del LAI y luego se añadieron los puntos por experiencia a cada imagen y así se obtuvo el valor para cada uno de éstos. Los resultados para el LAI, el EWT_{Canopy} y $\text{DMC}_{\text{Canopy}}$ se pueden apreciar en la Tabla 4.7.

Tabla 4.7: Valores del *Leaf Area Index* (LAI), *Equivalent Water Thickness – Canopy* (EWT_{Canopy}) y *Dry Matter Index – Canopy* ($\text{DMC}_{\text{Canopy}}$) de cada pino P_i (con $i = 1, 2, 3, 4, 5$) correspondiente a la experiencia E_j ($j = 1, 2, 3$).

Experiencia	Pino	LAI	$EWT_{\text{Canopy}} (g\ cm^{-2})$	$\text{DMC}_{\text{Canopy}} (g\ cm^{-2})$
E1	P1	1,899	0,06813	0,04943
	P2	1,899	0,04785	0,03104
	P3	1,899	0,04796	0,03459
E2	P1	1,200	0,03284	0,02488
	P2	1,200	0,03093	0,02284
	P3	1,200	0,02543	0,01936
E3	P1	0,800	0,01270	0,00950
	P2	0,800	0,01412	0,01007
	P3	0,800	0,01484	0,01125
	P4	0,800	0,01751	0,01420
	P5	0,800	0,02094	0,01555

4.2.4 Índices espectrales satelitales

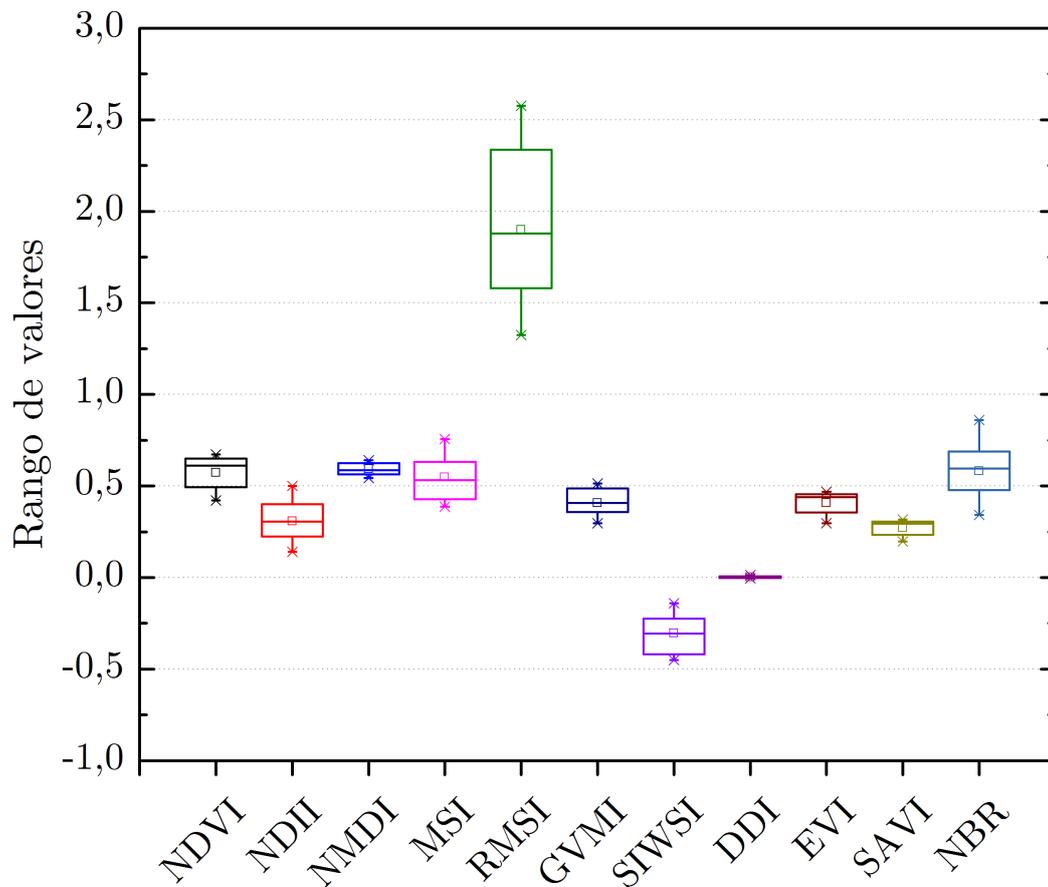
La cantidad de índices espectrales que se pueden calcular a partir de los datos otorgados por el sensor OLI son, realmente, una infinidad. Ahora bien, en base a los objetivos planteados de estudiar la relación que podría existir entre el empleo de información satelital para determinar valores del FMC, resulta relevante analizar índices que, como se estudió en el Capítulo 2, contemplan valores de reflectancias en la región del infrarrojo de onda corta (SWIR) e infrarrojo cercano (NIR). De esta forma, y en torno a los objetivos del proyecto, solo se estudiaron 11 índices espectrales a nivel satelital. El rango de valores y los autores de éstos índices se pueden apreciar en la Tabla 4.8.

Por otro lado, una representación gráfica de los rangos de los índices se presenta en la Figura 4.15 por medio de diagramas de caja.

¹Reverb echo: <https://reverb.echo.nasa.gov/>

Tabla 4.8: Valores mínimos, máximos, medios y desviación estándar (σ) de los índices espectrales obtenidos a través de información satelital.

Índice	Valores				Autor
	Mín.	Máx.	Media	σ	
NDVI	0,422	0,671	0,573	0,090	Rouse <i>et al.</i> (1973)
NDII	0,139	0,501	0,308	0,106	Hardisky <i>et al.</i> (1983)
NMDI	0,544	0,640	0,594	0,033	Wang y Qu (2007)
MSI	0,388	0,755	0,548	0,114	Hunt Jr y Rock (1989)
RMSI	1,324	2,576	1,900	0,404	Hunt Jr y Rock (1989)
GVMi	0,297	0,514	0,408	0,069	Ceccato <i>et al.</i> (2002b)
SIWSI	-0,451	-0,139	-0,303	0,101	Fensholt y Sandholt (2003)
DDI	-0,005	0,013	0,003	0,006	Gulácsy y Kovács (2015)
EVI	0,296	0,470	0,408	0,058	Huete <i>et al.</i> (2002)
SAVI	0,196	0,316	0,272	0,042	Huete (1988)
NBR	0,342	0,860	0,582	0,146	Key y Benson (2002)

**Figura 4.15:** Rango de valores de los índices espectrales obtenidos por información satelital.

Fuente: Elaboración propia.

5 | Modelamiento en PROSPECT

Lo primero en analizar son los resultados de las regresiones efectuadas a la base de datos LOPEX93 (*Leaf Optical Properties Experiment*– Hosgood *et al.*, 1994), donde se buscó relacionar la clorofila a+b (C_{a+b}), los carotenoides (C_{car}) y el EWT, todos de LOPEX93, con índices espectrales como variables independientes, con el fin de obtener modelos estadísticos para estimar, indirectamente, las mismas variables pero de la vegetación bajo estudio y así utilizar PROSPECT, un modelo de transferencia radiativa a nivel de hoja. La simulación del espectro permite contar con un mayor rango de posibilidades para índices espectrales (entre los 400 y 2.500 nm), sobre todo en la región del SWIR que, como se explicó en el [Estado del Arte](#), es la región que presenta mayor relación con el contenido de humedad de la vegetación, siendo ésta una de las variables más relevantes en la gestión del riesgo de incendios forestales. McAllister *et al.* (2012) relacionó el tiempo de ignición con la humedad de vegetación viva y determinó que ésta predice un 74–80 % de la ignición. De esta forma, la finalidad se traduce en generar modelos estadísticos que puedan explicar, en base de solo el uso del espectrómetro e índices espectrales, 3 variables por medio de la simulación en PROSPECT.

5.1. Parámetros de entrada de PROSPECT

Existen algunas variables de entrada de PROSPECT que han sido ampliamente estudiadas con el fin de realizar una metodología más sencilla para la estimación de su valor. Tal es el caso de la cantidad de clorofila (C_{a+b}), la cantidad de carotenoides (C_{car}) y el equivalent water thickness (EWT). De esta forma, a partir de modelos estadísticos es posible utilizar la base de datos LOPEX93 (Hosgood *et al.*, 1994) con el fin de obtener una fórmula con la cual se pueda estimar, indirectamente, la cantidad de las tres variables mencionadas con anterioridad para el presente estudio. Se utilizaron el 97 % de las muestras (320) de LOPEX93, es decir los valores de C_{a+b} , C_{car} y EWT_{Leaf} y sus correspondientes espectros reflectivos entre los 400–2.500 nm para obtener los modelos que se darán a conocer a continuación. Los parámetros de entrada de PROSPECT se pueden apreciar en la [Tabla 5.1](#).

Tabla 5.1: Parámetros de entrada de PROSPECT.

Nombre	Sigla
Cantidad de clorofila a+b	C_{a+b}
Cantidad de carotenoides	C_{car}
<i>Equivalent Water Thickness</i>	EWT
<i>Leaf mass per area</i>	LMA
Pigmentos café	C_b
Parámetro de estructura interna	N

5.1.1 Cantidad de clorofila a+b (C_{a+b})

En la literatura se encontró una gran relación entre la clorofila y varios índices espectrales que podrían estimarla. Se decidió optar por aquel creado por Gitelson *et al.* (2003) (Índice de Gitelson – I.G.1), debido a que el autor principal lleva bastantes años en el estudio de la reflectancia de la vegetación y, por otro lado, su índice ha sido utilizado en otros estudios, como en el de le Maire *et al.* (2004), entre otros. Se probó con otros índices como el mSR-like (Datt, 1999b), el NDVI (Rouse *et al.*, 1973) y otro índice que elaboró el Dr. Gitelson, que se le llamó I.G.2 (Gitelson y Merzlyak, 1994), pero ninguno logró resultados como el I.G.1. Existen bastantes más, pero también hay que considerar la región que otorga el espectrómetro y, por consiguiente, índices que requieran de valores

de reflectancia bajo los 650 nm no se consideraron (como la absorción de clorofila ocurre en el rango visible, no existen índices para su estimación por sobre el límite superior que otorga el espectrómetro i.e. 1.100 nm). La [Figura 5.1](#) presenta la gráfica de la regresión, en donde se observa una relación lineal entre la clorofila (C_{a+b}) y el Índice de Gitelson (I.G.1) para 320 datos de LOPEX93. Así, es posible establecer que existe una relación bastante estrecha entre el índice propuesto por [Gitelson et al. \(2003\)](#) y la cantidad de clorofila. En base a lo anterior es que se determina que la clorofila se estimará a partir de la relación estadística obtenida del análisis.

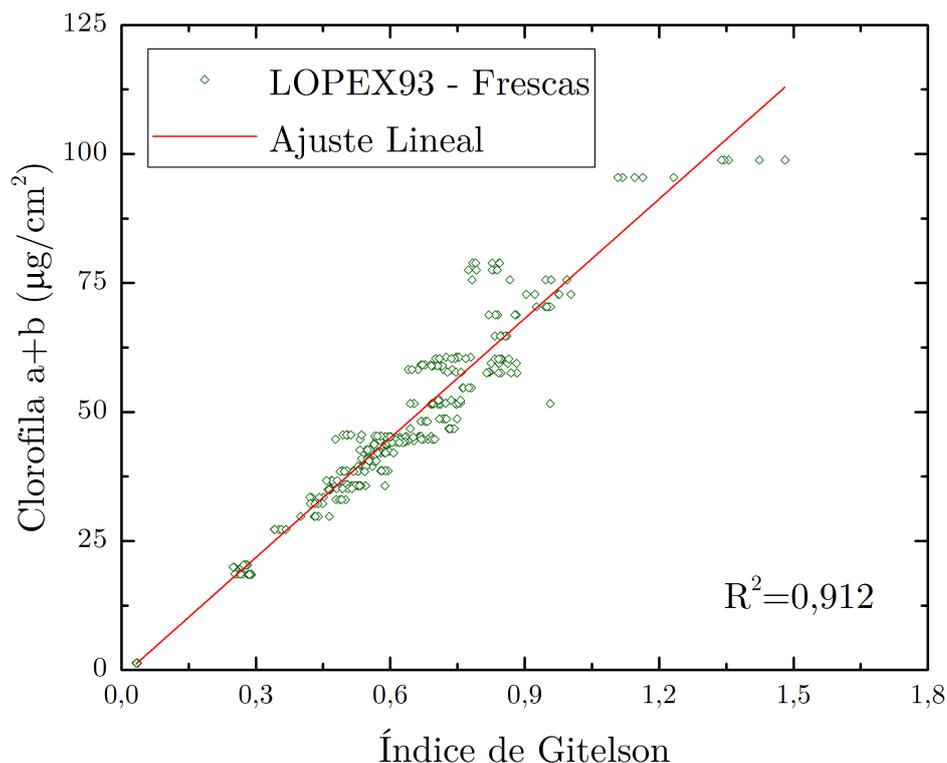


Figura 5.1: Relación lineal entre la cantidad de clorofila a+b (C_{a+b}) y el Índice de Gitelson a partir de información obtenida de la base de datos LOPEX93.

Fuente: Elaboración propia.

En tanto, la relación a utilizar para estimar, indirectamente, la cantidad de clorofila a+b (C_{a+b}) en el estudio será:

$$C_{a+b} = 77,183 \cdot \text{I.G.1} - 1,361 \left(\frac{\mu\text{g}}{\text{cm}^2} \right) \quad (5.1)$$

Donde I.G.1 corresponde al Índice de Gitelson, que como se explicó en la [Sección 3.4.2 \(Análisis espectral, Capítulo 3\)](#), equivale a:

$$\text{I.G.1} = \frac{\rho_{775}}{\rho_{718}} - 1$$

Donde ρ_{775} y ρ_{718} corresponden a la reflectancia en las longitudes de onda de 775 y 718 nm, respectivamente, cuyos valores se obtienen directamente del análisis espectral, siendo éstas las únicas variables para determinar el contenido de clorofila. La relación se determina como factible debido a que se aprecia una alta correlación entre las variables ($R^2=0,912$).

Por otro lado, se calculó el error medio cuadrático ($\text{RMSE}_{C_{a+b}}$) de la siguiente forma:

$$\text{RMSE}_{C_{a+b}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (C_{a+b_i} - C_{a+b_{Mi}})^2} = 5,124 \left(\frac{\mu\text{g}}{\text{cm}^2} \right) \quad (5.2)$$

Donde C_{a+b_i} es la clorofila de la vegetación i ($i \in \{1, \dots, 320\}$) de la base de datos de LOPEX93 y $C_{a+b_{Mi}}$ es la clorofila correspondiente al modelo determinado en la ecuación (5.1). La variación de los datos correspondientes a la clorofila a+b de las 320 muestras estudiadas de LOPEX93 se pueden apreciar en la [Tabla 5.2](#).

Tabla 5.2: Valor mínimo, máximo, promedio y desviación estándar (σ) de la clorofila a+b (C_{a+b}) de las muestras de LOPEX93.

Variable	Valores ($\mu\text{g}/\text{cm}^2$)			
	Mín	Máx	Promedio	σ
C_{a+b}	1,36	98,80	47,28	17,30

5.1.2 Cantidad de carotenoides (C_{car})

El índice propuesto por [Gitelson *et al.* \(2003\)](#) también es un buen estimador de la cantidad de carotenoides, según indican en el estudio. Los resultados de la regresión se pueden apreciar en la [Figura 5.2](#), en donde se destaca una tendencia lineal de las variables, pero existe una mayor dispersión de los datos que en el caso de la clorofila, que radican en una menor correlación y mayor RMSE.

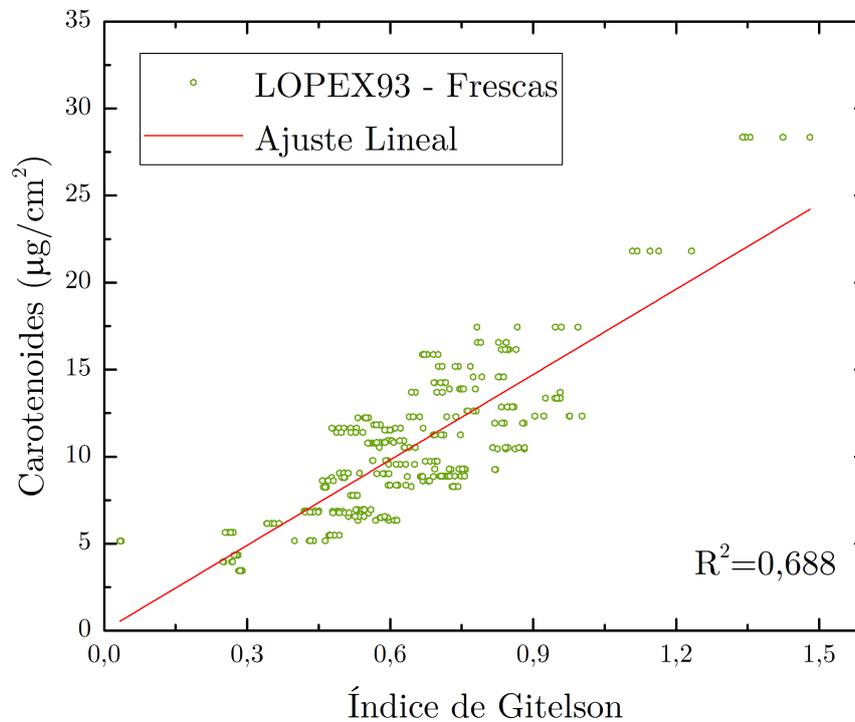


Figura 5.2: Relación lineal entre la cantidad de carotenoides (C_{car}) y el Índice de Gitelson a partir de información obtenida de la base de datos LOPEX93.

Fuente: Elaboración propia.

La relación estadística entre la cantidad de carotenoides y el Índice de Gitelson equivale a:

$$C_{car} = 16,3471 \cdot I.G.1 + 0,0044 \left(\frac{\mu g}{cm^2} \right) \quad (5.3)$$

En donde I.G.1 corresponde al Índice de Gitelson. Por otro lado, se calculó el error medio cuadrático ($RMSE_{C_{car}}$) de la siguiente forma:

$$RMSE_{C_{car}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (C_{car_i} - C_{car_{Mi}})^2} = 2,3517 \left(\frac{\mu g}{cm^2} \right) \quad (5.4)$$

Donde C_{car_i} son los carotenoides de la vegetación i ($i \in \{1, \dots, 320\}$) de la base de datos de LOPEX93 y $C_{car_{Mi}}$ son los carotenoides correspondiente al modelo determinado en la ecuación (5.3). La variación de los datos correspondientes a los carotenoides de las 320 muestras estudiadas de LOPEX93 se pueden apreciar en la [Tabla 5.3](#).

Tabla 5.3: Valor mínimo, máximo, promedio y desviación estándar (σ) de los carotenoides (C_{car}) de las muestras de LOPEX93.

Variable	Valores ($\mu g/cm^2$)			
	Mín	Máx	Promedio	σ
C_{car}	3,45	28,35	10,31	4,22

Cabe destacar que se buscó el mejor modelo entre índices como el mSR-like ([Datt, 1999b](#)) ($R^2=0,646$; ajuste exponencial) y un segundo índice propuesto por [Gitelson y Merzlyak \(1994\)](#), que se le llamó Índice de Gitelson 2 ($R^2 = 0,613$; ajuste exponencial), donde el I.G.1 tuvo los mejores resultados (mayor R_2 y menor RMSE).

5.1.3 Equivalent water thickness (EWT)

El EWT se puede determinar a partir de dos metodologías, como se explicó en la [Sección 3.4.2 \(Análisis espectral\)](#). La primera consiste en la técnica del secado de la vegetación en el horno (destruktiva), en donde se calcula el cociente entre la diferencia de la masa fresca y masa seca dividido por el área de una aguja de pino. La segunda metodología (no destructiva) es la que se dará a conocer en la presente sección, y alude a una metodología más eficiente en términos tiempo por ser un modelo estadístico. Así, se establece como variable independiente del EWT el índice espectral *Water Index* ([Peñuelas et al., 1997](#)), que ha sido ampliamente utilizado para determinar la cantidad de agua de la vegetación, y teniendo sus mejores resultados con el EWT ([Mobasheri y Fatemi, 2013](#)). De esta forma, nuevamente se le realiza una regresión a los datos de la base de datos de LOPEX93, en donde se obtiene la gráfica presente en la [Figura 5.3](#). A partir de dicho esbozo, se puede establecer una relación lineal entre el índice WI y el EWT. Estas se explican con una correlación de un 95 %.

De esta forma, es posible determinar, indirectamente, el EWT en función del WI a partir de la siguiente expresión:

$$EWT = 0,663 \cdot WI - 0,669 \left(\frac{g}{cm^2} \right) \quad (5.5)$$

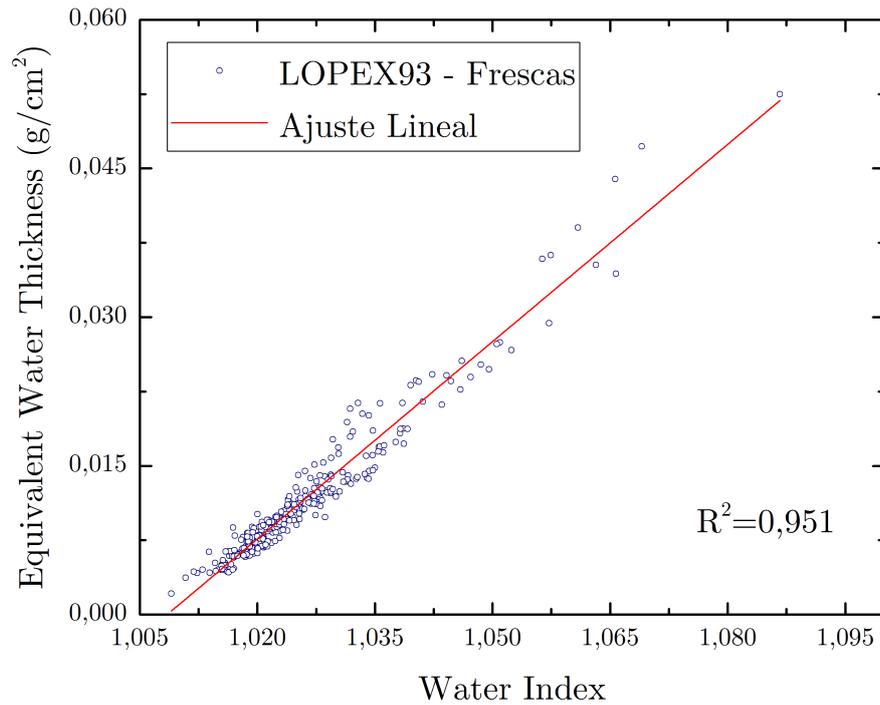


Figura 5.3: Relación lineal entre el EWT de información obtenida de la base de datos LOPEX93 y el Water Index propuesto por Peñuelas *et al.* (1997).

Fuente: Elaboración propia.

Por otro lado, se calculó el error cuadrático medio ($RMSE_{EWT}$) de la siguiente forma:

$$RMSE_{EWT} = \sqrt{\frac{1}{n} \sum_{i=1}^n (EWT_i - EWT_{Mi})^2} = 0,00155 \left(\frac{g}{cm^2} \right) \quad (5.6)$$

Donde EWT_i es el EWT de la vegetación i de la base de datos de LOPEX93 y EWT_{Mi} es el EWT correspondiente al modelo determinado en la ecuación (5.5). Cabe destacar que se utilizó el WI como índice espectral para predecir el EWT no solo porque en la literatura ha tenido buenos resultados, ya que también existen índices como el NDII, NDWI, MSI y otros que también han sido utilizados para estimar el EWT con buenos resultados. Se utilizó el WI porque es posible de obtenerlo por medio del rango espectral que otorga el espectrómetro, lo cual es fundamental para poder realizar el modelo propuesto en la ecuación (5.5). Por otro lado, la variación de los datos correspondientes al EWT de las 320 muestras estudiadas de LOPEX93 se pueden apreciar en la [Tabla 5.4](#).

Tabla 5.4: Valor mínimo, máximo, promedio y desviación estándar (σ) del EWT de las muestras de LOPEX93.

Variable	Valores (g/cm^2)			
	Mín	Máx	Promedio	σ
EWT	0,00210	0,05249	0,01144	0,00686

5.1.4 Pigmentos café – C_b

La determinación de los pigmentos café se hace un tanto engorrosa cuando la vegetación está vieja. En este experimento la vegetación está completamente viva. [Contreras \(2016\)](#) empleó una metodología

de un ajuste de curvas entre aquella obtenida experimentalmente (con el espectrómetro) y la curva simulada, en donde fue variando la simulación para hallar el valor de los pigmentos café. El valor de los pigmentos café que necesita PROSPECT varía entre 0 y 1, en donde se determina que un valor equivalente a 0 es vegetación con 0 pigmentos café (o 0 %) y un valor de 1 vendría siendo una hoja/aguja 100 % de color café. Así, los resultados de Contreras (2016) demostraron lo que se tuvo como hipótesis, es decir, un valor de 0 para la vegetación viva (que claramente se vea verde). Por ende, en el presente proyecto se empleará dicho valor.

5.1.5 Leaf mass per area – LMA

Otra variable de entrada de PROSPECT es la cantidad de masa seca de la hoja por unidad de área (LMA) (o también llamado DMC_{Leaf} . Se le continuará llamando LMA por facilidad de entendimiento para los *inputs* de PROSPECT). Este parámetro también podría haber sido determinado indirectamente de un modelo de regresión de un ajuste cuadrático según se estudió en la Sección 2.3.4.1, pero el índice utilizado para dicho análisis excede las capacidades del espectrómetro, por lo cual se utilizará el dato experimental del DMC.

A partir de la metodología para calcular el FMC (ver Sección 4.1.2) es posible establecer los valores del LMA, pero es necesario determinar los pasos a seguir para la obtención de los valores que determinan la variable, que es un función de la metodología establecida.

- (1) Por medio del uso de la balanza de precisión, se determinó el peso fresco de 1 sola aguja de pino a partir del promedio de diez de estas seleccionadas aleatoriamente buscando la representatividad de éstas con respecto a la muestra total. Este valor corresponde, entonces, al peso fresco (o *fresh weight* – W_f) para 1 sola aguja de pino representativa de la muestra para el análisis del FMC.
- (2) Luego, se procedió a secar las muestras para obtener el peso seco total de la muestra. Es decir, las 10 agujas representativas que se masaron para obtener el peso fresco (en el punto (1) anterior), ingresaron al horno separadas del resto de la muestra. Así, pasadas las 24 horas a 60°C, estas 10 agujas se masaron nuevamente para cuantificar su peso seco, y se dividió por 10 para obtener el peso seco (W_d) de una sola aguja de pino. Después, estas 10 agujas se juntaron al resto de la muestra y se obtuvo el peso seco total de la muestra, que determina el peso seco para el cálculo del FMC (FMC_{Medido}).
- (3) Finalmente, el peso seco de 1 aguja de pino (W_d) se dividió por el área de la misma. En este caso, el área se obtuvo mediante el procesamiento de una imagen adquirida a las 10 agujas de pino que se utilizaron en el punto (1). Éstas se colocaron sobre una hoja blanca y se les tomó una fotografía (con un Apple iPhone 6) y luego dichas fotografías se procesaron en el programa ImageJ, en donde se realizaron una serie de ajustes para determinar el área de las hojas. Dichos ajustes y metodología se pueden apreciar en el Anexo H. El mismo programa realiza un breve análisis estadístico que determina el promedio de las áreas, siendo éste el valor a utilizar como área de la aguja de pino.

5.1.6 Parámetro de estructura interna – N

Esta variable fue la más compleja de determinar, debido a que ninguna de las relaciones propuestas para su cálculo (en función del SLA – *Specific Leaf Area*, que es equivalente a LMA^{-1} ; Ceccato *et al.*, 2001; Jacquemoud y Baret, 1990) sirve para agujas de pino (ver las ecuaciones 3.4 y 3.5). La razón del porqué no sirven se debe a que los valores del SLA obtenidos (y en general para agujas de pino) son menores a $0,1\text{ cm}^2\text{ mg}^{-1}$, lo que resulta en raíces negativas al ocupar la ecuación (3.5) y valores de $N < 0$ al utilizar la ecuación (3.4). La razón fisiológica del porqué de lo anterior radica en la diferencia que existe entre los parámetros de estructura interna de hojas (vegetación latifoliada) y agujas de pino (vegetación conífera), que son muy distintas entre sí (Ollinger, 2011). La diferencia de éstas se puede

apreciar en la [Figura G.1](#) en el [Anexo G](#). De esta forma, el tema se discutió con Carola Contreras ([Contreras, 2016](#)), en donde se llegó a la siguiente metodología (alternativa):

- El primer método consistió en realizar un ajuste hiperbólico a los datos dentro de la base de datos de LOPEX93 para muestras frescas, buscando explicar “N” a partir de los valores de SLA de las muestras en dicha base de datos. El método no entregó resultados aceptables, debido a la gran dispersión encontrada en los datos ($R^2 < 0,5$).
- El segundo método se puso en marcha luego de que todos los otros parámetros de PROSPECT, excepto N, fueron determinados. Así, el método consistió en ajustar el parámetro N con el fin de lograr una mayor similitud entre el espectro de reflexión simulado por PROSPECT y aquella fracción del espectro obtenida a partir del uso del espectrómetro, es decir, una metodología visual mediante un análisis de *ceteris paribus*.¹ Los resultados fueron racionales en materia de comparación con el espectro medido, en donde se pudo establecer que los valores de N oscilaron entre 1,25 y 3,0, siendo la media el valor 2 (ver [Tabla 5.6](#)). Hay que destacar que ésta metodología es factible debido a que si se revisan las variaciones de los parámetros de PROSPECT (ver [Figura 3.7](#) del [Capítulo 3](#)), el valor del parámetro de estructura interna juega un rol importante en las variaciones en torno a la región de análisis del espectrómetro (entre los 650–1.100 nm).

5.2. Resultados de los parámetros para PROSPECT

Los resultados de la regresión aplicada a la base de datos LOPEX93 se pueden apreciar en la [Tabla 5.5](#).

Tabla 5.5: Resultados de los modelos estadísticos para determinar la clorofila (C_{a+b}), EWT_{Reg} (EWT a partir del modelo de regresión) y carotenoides (C_{car}).

Experiencia	Muestra	EWT_{Reg} [g/cm ²]	C_{a+b} [μg/cm ²]	C_{car} [μg/cm ²]
1	P1	0,0920	108,12	23,19
	P2	0,0504	116,15	24,89
	P3	0,0639	123,61	26,47
2	P1	0,0511	73,01	15,76
	P2	0,0611	75,47	16,28
	P3	0,0482	76,35	16,46
3	P1	0,0364	71,84	15,51
	P2	0,0415	68,62	14,83
	P3	0,0332	60,76	13,16
	P4	0,0269	62,19	13,46
	P5	0,0237	60,85	13,18

Sin embargo, a partir de la [Tabla 5.5](#), aún faltan el parámetro de estructura interna (N) y los valores del LMA para poder ejecutar PROSPECT. No obstante, es en este punto donde nace la primera inquietud de los resultados: el rango de valores que se obtuvo a partir del modelo de regresión para determinar el EWT. Cuando se busca modelar con PROSPECT, se deben ingresar los parámetros al programa en la página [OpticLeaf](#),² pero estos valores tienen un rango determinado permitido. El rango

¹Todo lo demás constante.

²OpticLeaf: <http://opticleaf.ipgp.fr/index.php?page=prospect>

de valores admitido por PROSPECT para el EWT varía entre los $0 \leq \text{EWT} \leq 0,05 \text{ [g/cm}^2\text{]}$, criterio que se cumple solo para cierto rango de valores obtenidos por el modelo (EWT_{Reg}). Es así como surge la idea de contrastar los valores del EWT obtenido experimentalmente y aquel adquirido a partir del modelo de regresión. En efecto, la variación es significativa, y la correlación entre ambos es baja. Los resultados de dicha comparación se pueden apreciar en la [Figura 5.4](#).

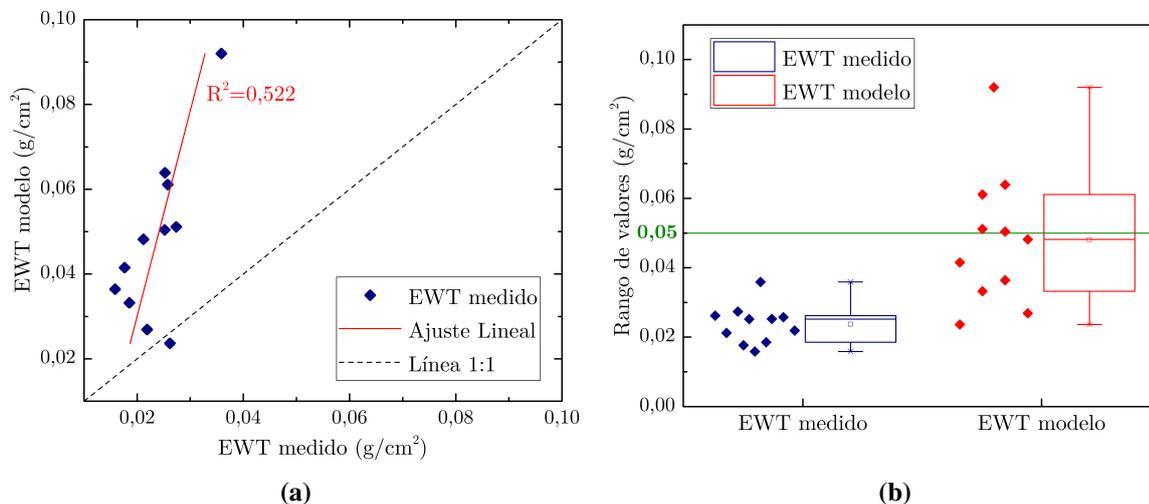


Figura 5.4: Gráficas comparativas de las diferencias entre el EWT medido en laboratorio y aquel obtenido por el modelo de regresión. (a) se puede apreciar una correlación bastante baja entre las variables estudiadas, como también una sobrestimación de los datos obtenidos por el modelo con respecto a los valores experimentales; (b) diagrama de cajas para observar las variaciones de los rangos de ambas metodologías, donde la línea horizontal determina el valor máximo del EWT permitido por PROSPECT para la simulación.

Fuente: Elaboración propia.

De la [Figura 5.4a](#) se puede apreciar que hay una baja correlación entre ambas variables que, en rigor, debiesen haber sido similares, pero el modelo se alejó en demasía de los valores obtenidos experimentalmente. Lo anterior se puede validar, visualmente, mediante el diagrama de cajas presente en la [Figura 5.4b](#). Los valores del EWT del modelo adquieren una sobrestimación de los datos, donde la mayoría de estos también se alejan del valor máximo permitido por PROSPECT para la simulación (línea verde horizontal situada a los $0,05 \text{ g/cm}^2$). La media de los valores del EWT obtenido experimentalmente equivale a $0,0237 \text{ (g/cm}^2\text{)}$ versus una media de $0,048 \text{ (g/cm}^2\text{)}$ para el EWT determinado por el modelo de regresión. Esta situación se torna interesante porque para más de 300 muestras analizadas de la base de datos LOPEX93 por el modelo de regresión con el *Water Index* como variable independiente, la correlación obtenida fue de $R^2=0,951$, como se estudió con anterioridad. Sin embargo, dicha base de datos no presenta información de muestras de especies coníferas, como lo es el caso de la vegetación analizada en presente estudio, sino que presenta datos de muestras de vegetación con tipos de hoja latifoliadas i.e. anchas y planas, a lo cual se le puede atribuir el error encontrado entre los datos proporcionados por el modelo y aquel medido en el laboratorio.

Por otro lado, para el caso del LMA, no se cuenta con la región del espectro para poder generar un modelo de regresión en base a índices espectrales que puedan determinarla indirectamente. Los resultados, en conjunto con los valores que se utilizaron del parámetro de estructura interna – N, se pueden apreciar en la [Tabla 5.6](#). Recordar que los valores del LMA son los mismos que los del DMC a nivel de hoja ($\text{LMA}=\text{DMC}_{\text{Leaf}}$), cuyos valores se obtuvieron en el [Capítulo 4](#), pero que se le llamará LMA con el fin de distinguir los parámetros que PROSPECT pide para su ejecución.

A partir de la [Tabla 5.6](#) se determina que los valores del EWT_{Leaf} (el *Equivalent Water Thickness* medido en laboratorio) presentan resultados bastante más racionales y cumplen con el rango de valores

permitidos por PROSPECT para poder simular el espectro. Dado el alto error hallado entre los valores del EWT obtenido a partir del modelo de regresión (inclusive con un $R^2=0,951$) y el obtenido en laboratorio, que asciende a una media de 103 % de error, es que resulta importante destacar que las diferencias son notorias debido a que la base de datos LOPEX93 cuenta solo con especies con tipo de hoja latifoliado (hojas planas y anchas), y no presenta muestras coníferas, como el caso de la especie estudiada en el presente proyecto.

Tabla 5.6: Resultados experimentales del EWT_{Leaf} y del LMA (ambos medidos en laboratorio para una aguja representativa de la muestra), y se presentan los valores de N en base a la metodología propuesta anteriormente. Cabe destacar que EWT_{Leaf} y LMA utilizaron los valores de la [Tabla 4.3](#) para el área, el peso fresco y seco de una aguja de pino.

Experiencia	Muestra	EWT_{Leaf} (g/cm^2)	LMA (g/cm^2)	N
1	P1	0,03587	0,026	3,00
	P2	0,02520	0,016	2,10
	P3	0,02525	0,018	3,00
2	P1	0,02736	0,021	2,00
	P2	0,02578	0,019	2,00
	P3	0,02119	0,016	2,00
3	P1	0,01587	0,012	1,70
	P2	0,01765	0,013	1,60
	P3	0,01855	0,014	1,60
	P4	0,02189	0,018	1,25
	P5	0,02618	0,019	1,90

5.3. Resultados de la simulación

Una vez que se conocen los valores de entrada de PROSPECT, se puede comenzar la simulación del espectro. Dichos valores se ingresan en la página de [OpticLeaf \(2015b\)](#), en donde el resultado es una gráfica visual que trae consigo un archivo de texto, que se descarga y trae los valores de la reflectancia a determinada longitud de onda, con 1 nm de resolución espectral. Así, se puede observar y tener la información del espectro desde los 400 hasta los 2.500 nm .

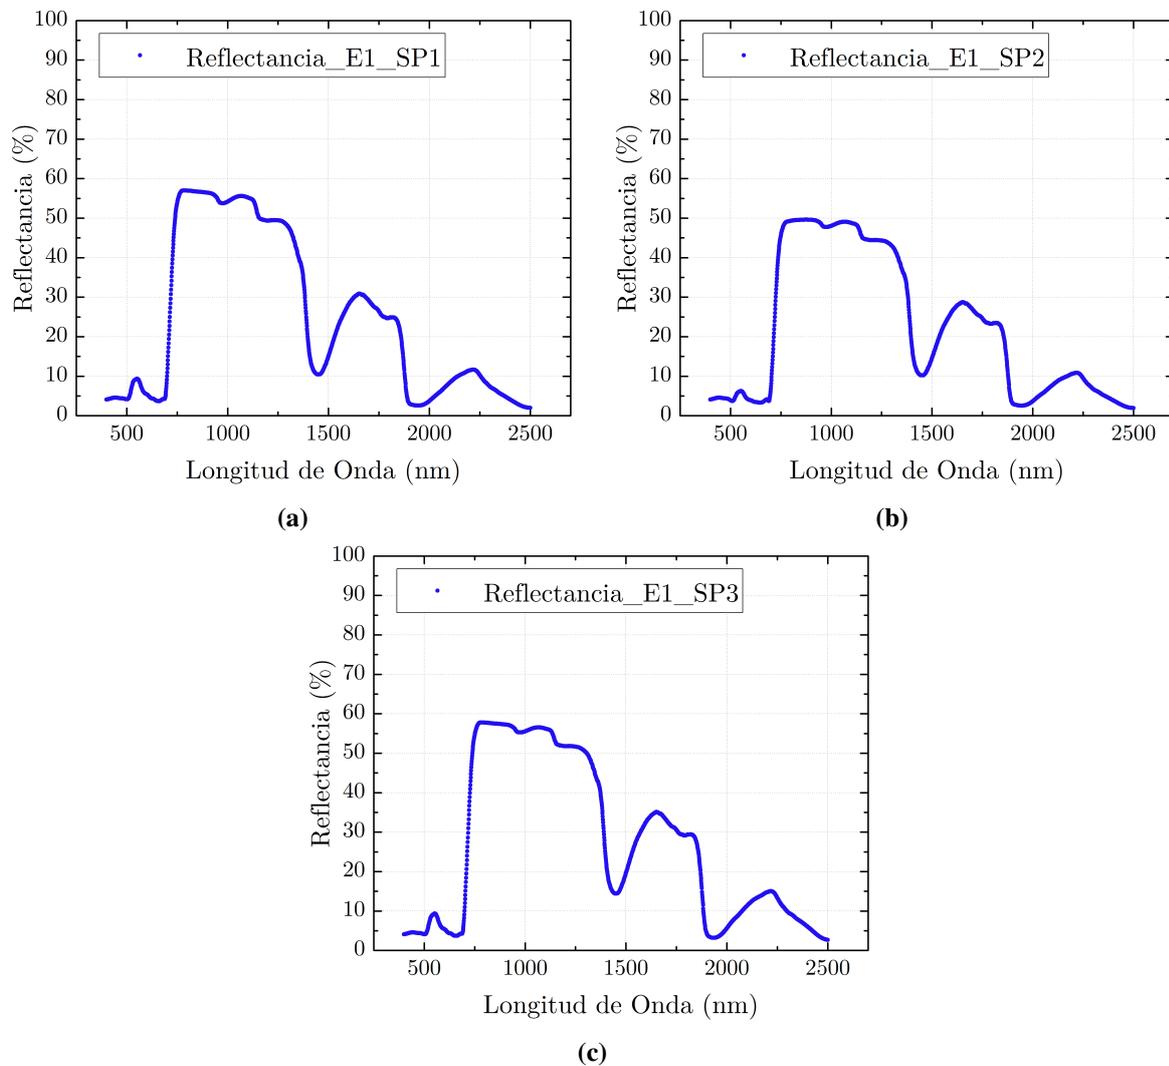


Figura 5.5: Gráficos del espectro simulado para la experiencia 1, donde (a), (b) y (c) corresponden a la reflectancia simulada con PROSPECT del pino 1, 2, y 3, respectivamente.

Fuente: Elaboración propia.

Como se puede apreciar en los gráficos de las figuras 5.5, 5.6 y 5.7 se está en presencia de vegetación viva, que presenta absorción de agua en el SWIR (las curvas en donde disminuye la reflectancia a los 1.450 nm y en los 1.900 nm , aproximadamente). La simulación es bastante acorde a las curvas espectrales de vegetación viva. En la [Sección 5.3.1](#) se muestran los gráficos de tanto el espectro medido como el simulado.

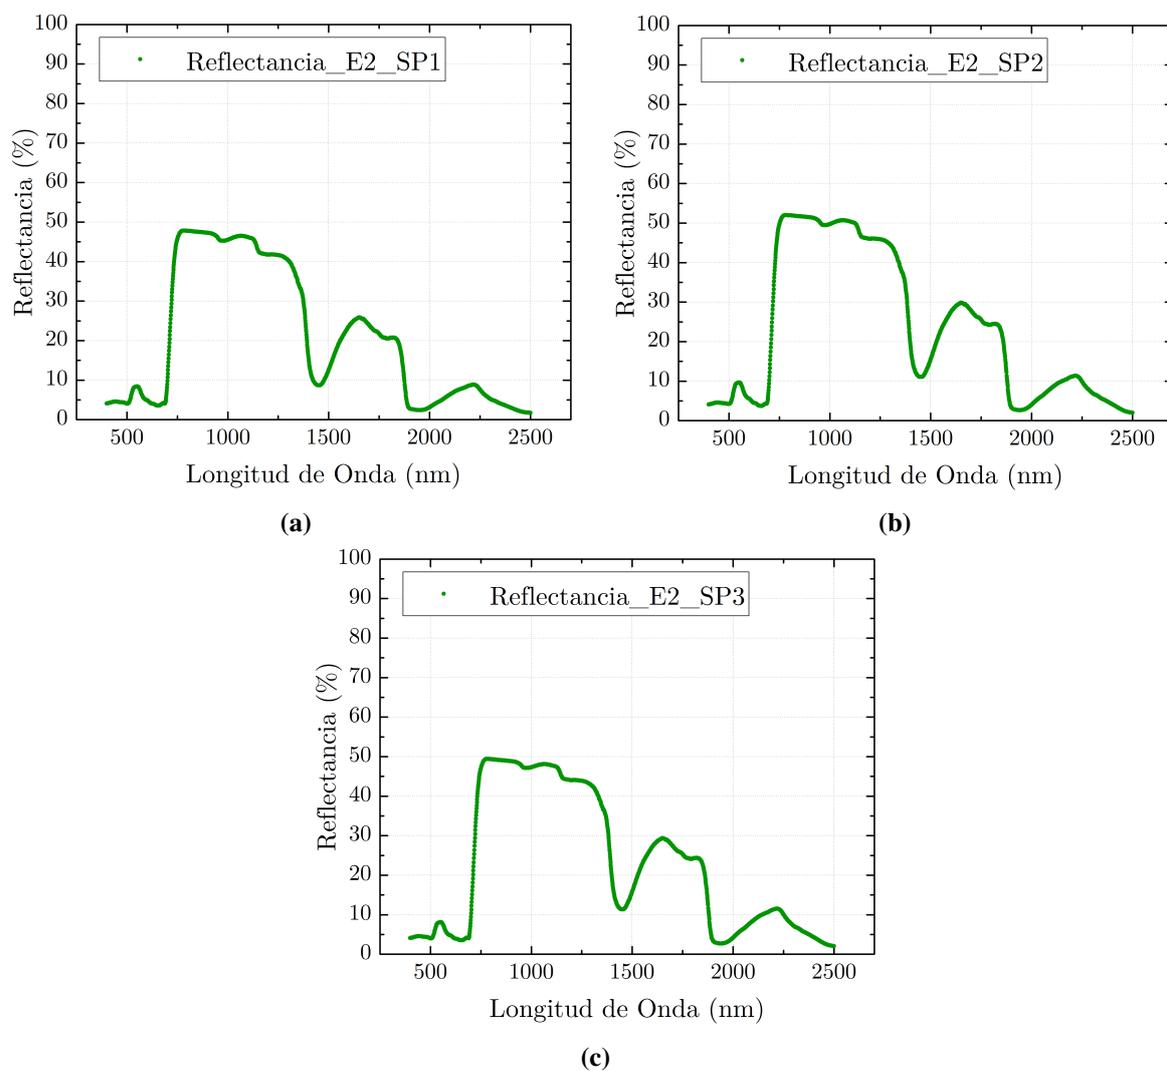


Figura 5.6: Gráficos del espectro simulado para la experiencia 2, donde (a), (b) y (c) corresponden a la reflectancia simulada con PROSPECT del pino 1, 2, y 3, respectivamente.

Fuente: Elaboración propia.

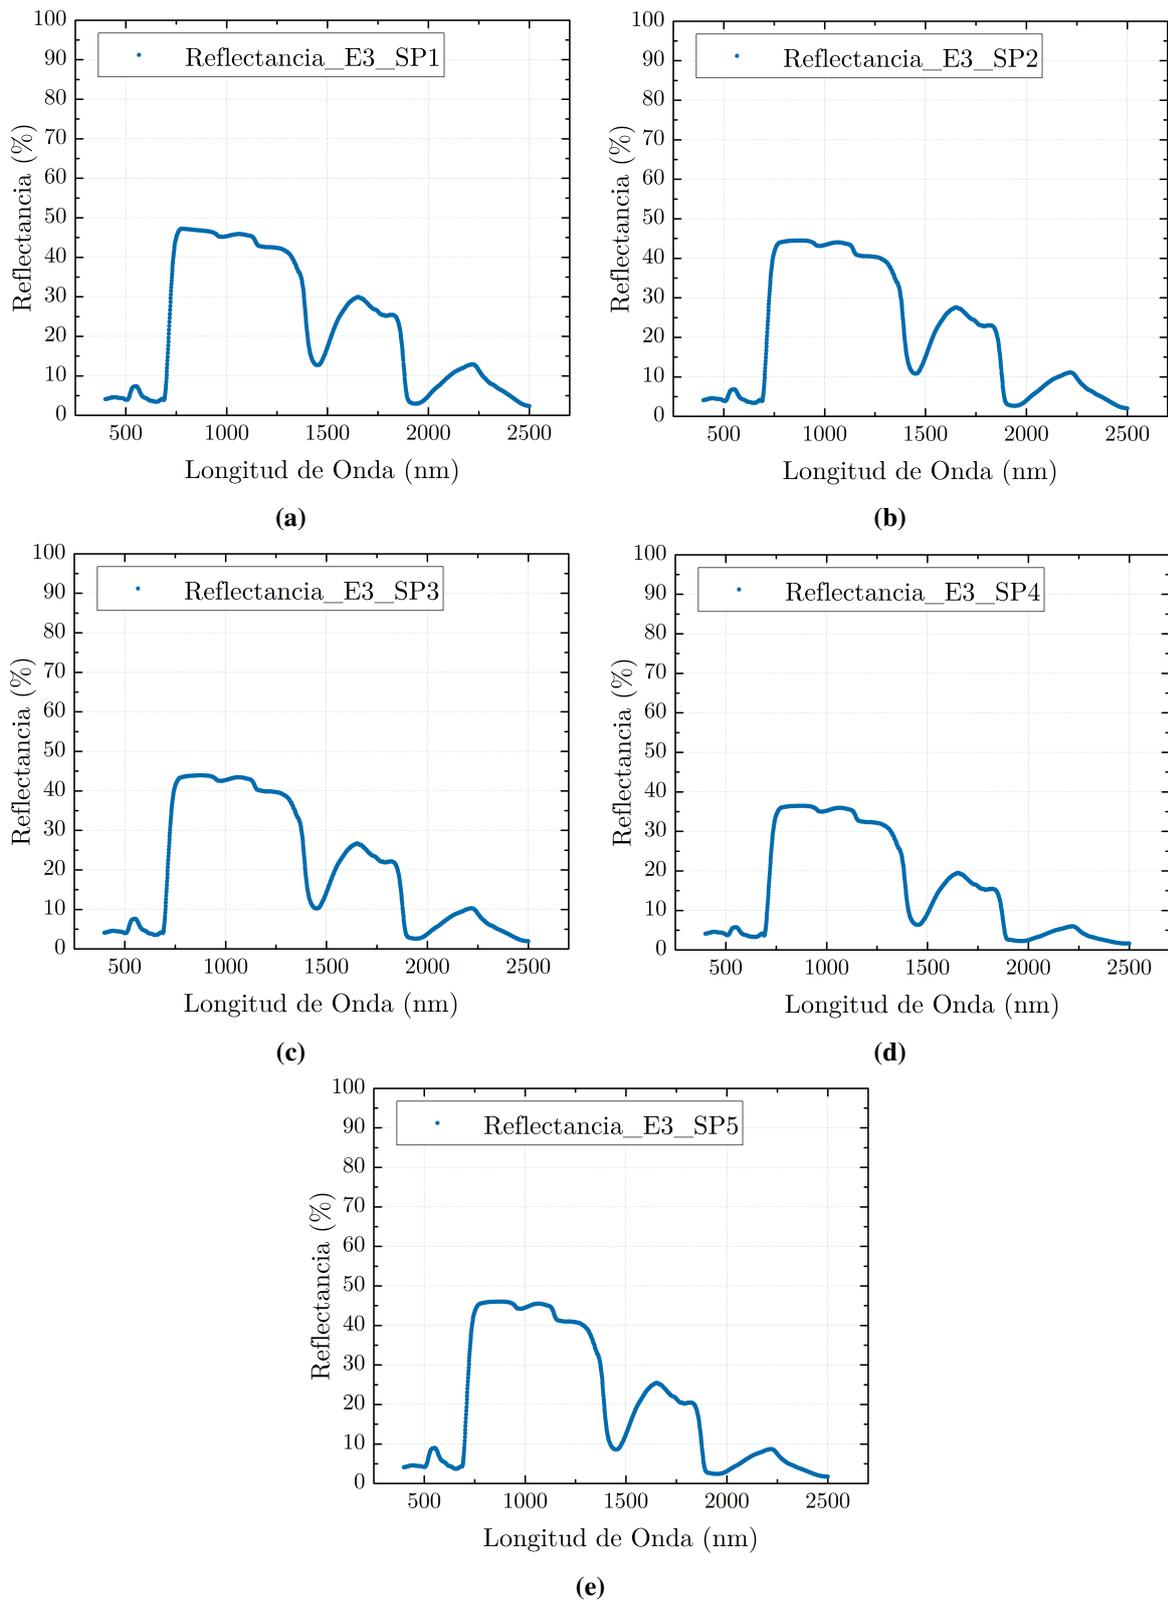


Figura 5.7: Gráficos del espectro simulado para la experiencia 3, donde (a), (b), (c), (d) y (e) corresponden a la reflectancia simulada con PROSPECT del pino 1, 2, 3, 4 y 5, respectivamente.

Fuente: Elaboración propia.

5.3.1 Comparación del espectro medido vs espectro simulado

A continuación se presentarán los resultados gráficos que mezclan tanto el espectro medido como el simulado para cada experiencia.

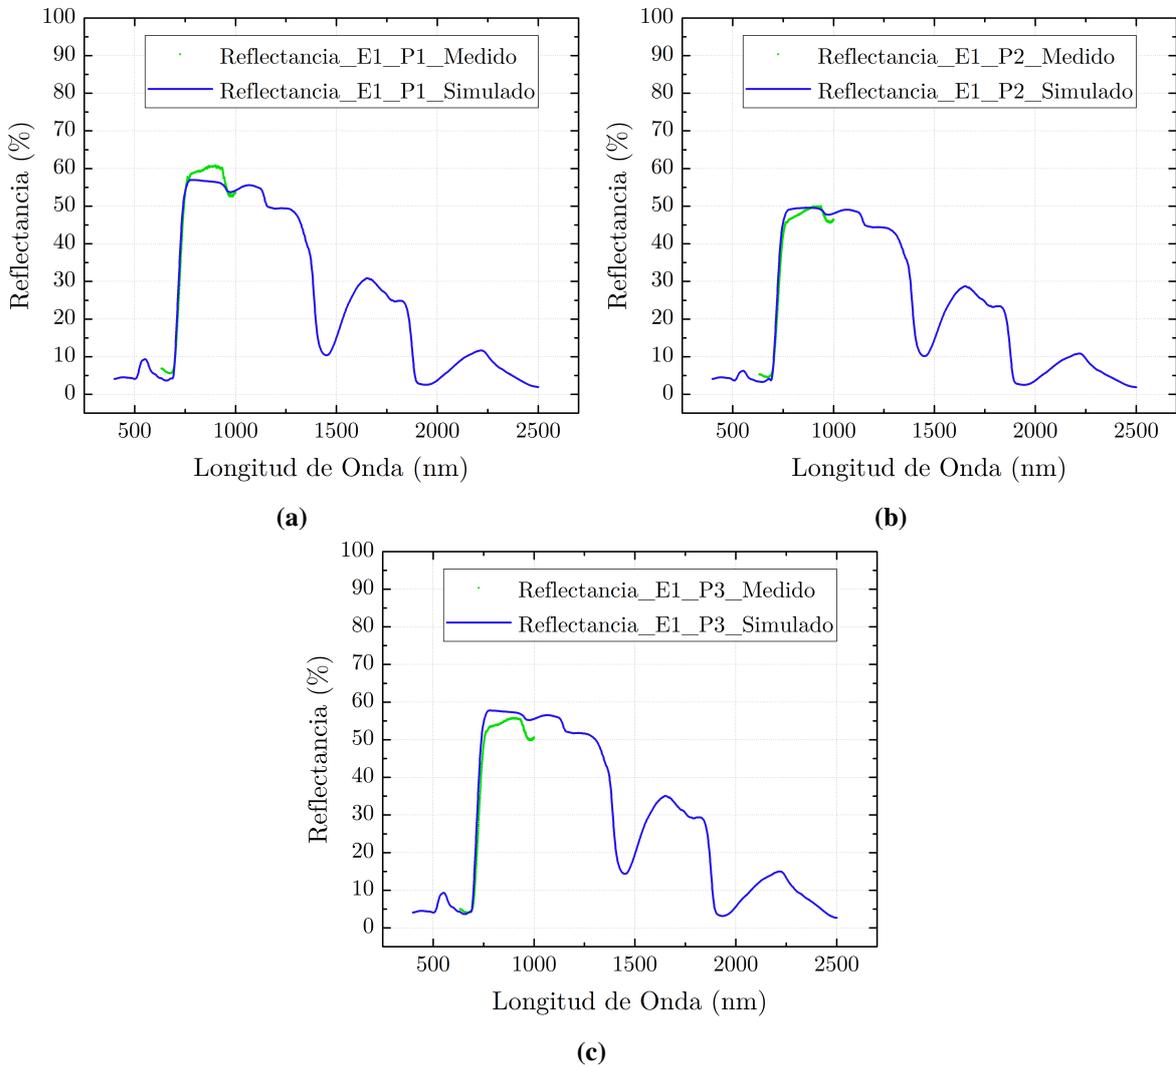


Figura 5.8: Gráficos del espectro simulado y medido para la experiencia 1, donde (a), (b) y (c) corresponden a la reflectancia medida y simulada con PROSPECT del pino 1, 2, y 3, respectivamente.

Fuente: Elaboración propia.

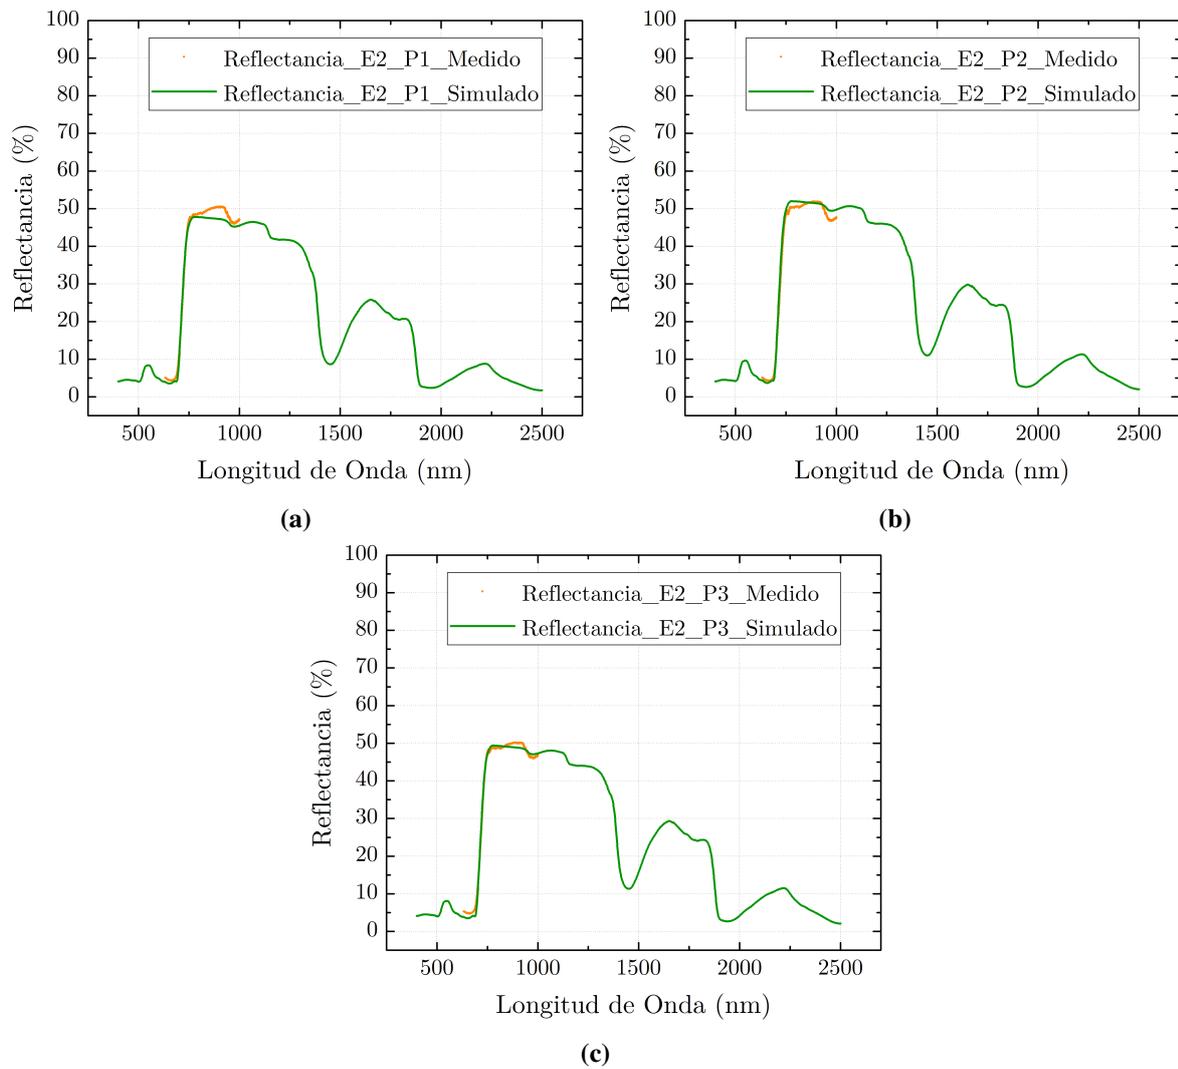


Figura 5.9: Gráficos del espectro simulado y medido para la experiencia 2, donde (a), (b) y (c) corresponden a la reflectancia medida y simulada con PROSPECT del pino 1, 2, y 3, respectivamente.

Fuente: Elaboración propia.

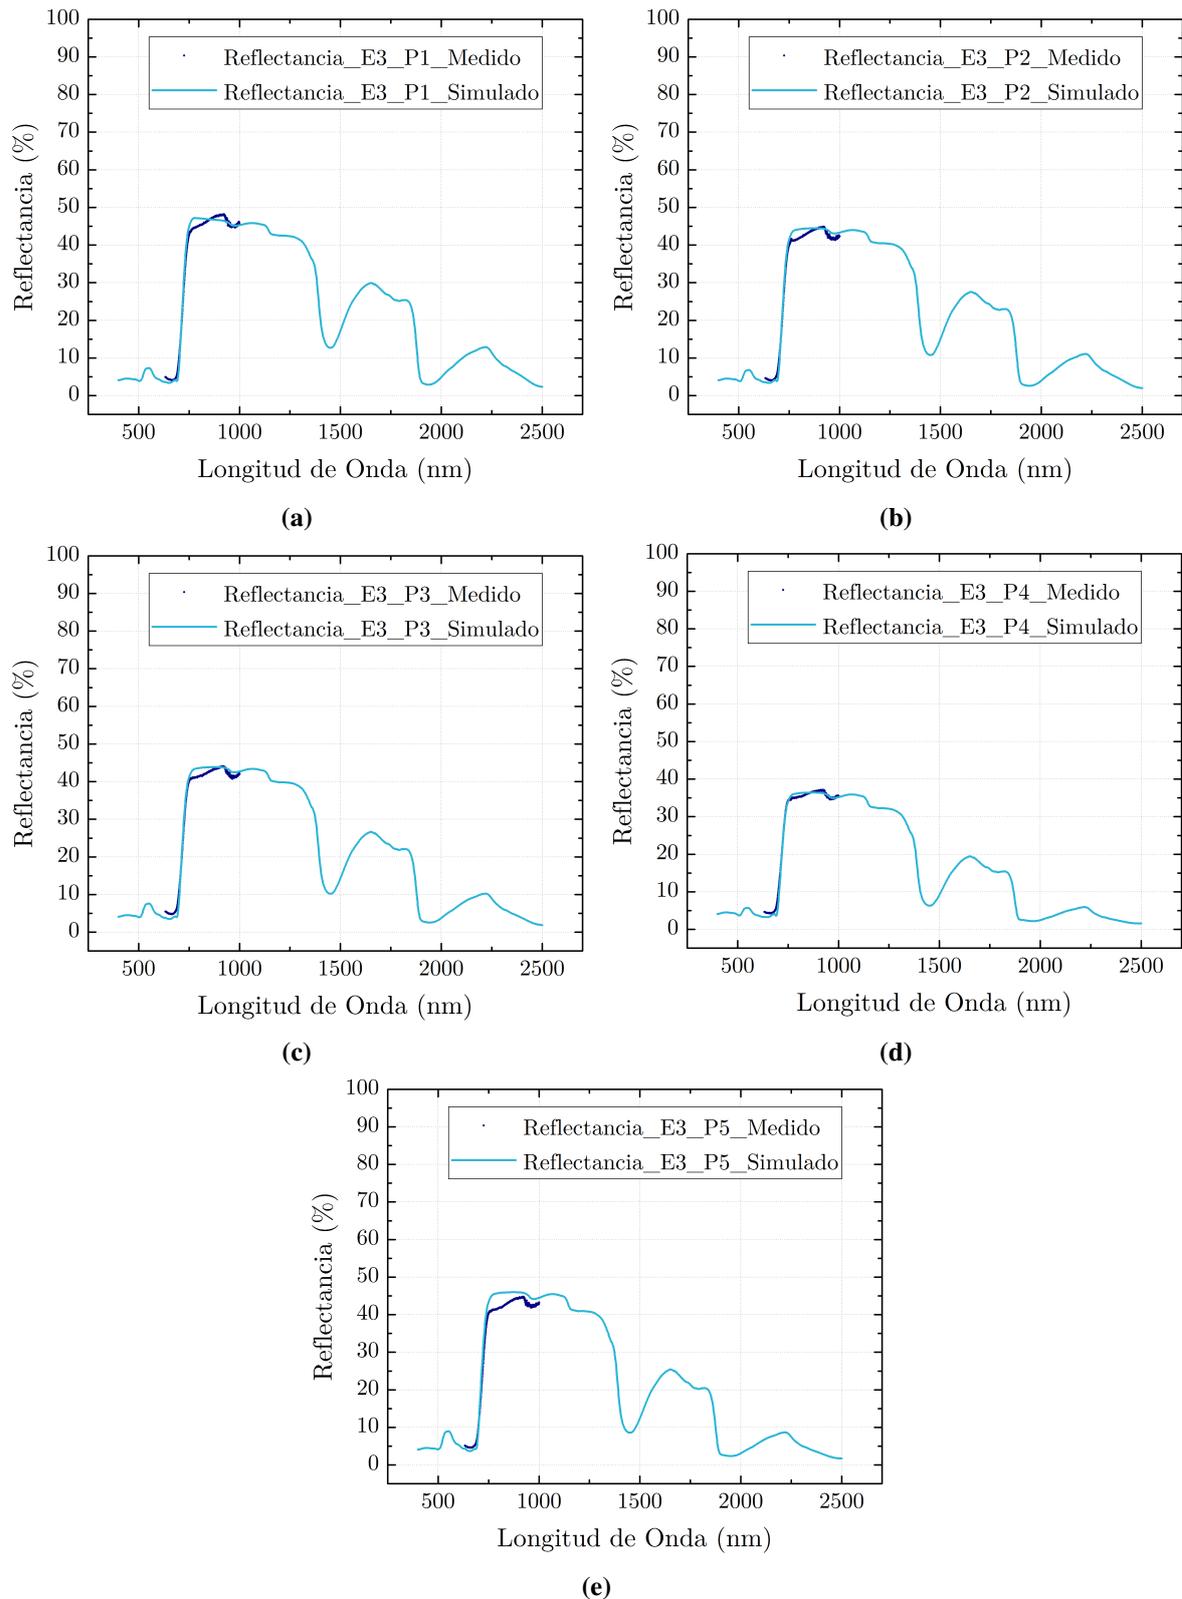


Figura 5.10: Gráficos del espectro simulado y medido para la experiencia 3, donde (a), (b), (c), (d) y (e) corresponden a la reflectancia medida y simulada con PROSPECT del pino 1, 2, 3, 4 y 5, respectivamente.

Fuente: Elaboración propia.

5.3.2 Índices del espectro simulado y del espectro medido

En la presente sección se presentan los resultados de una comparación entre los índices espectrales que se utilizaron en la sección **Índices obtenidos a partir del espectro medido** (4.1.3.1) y aquellos que se calcularon para el espectro simulado (los mismos), siendo éstos un conjunto de índices que se han utilizado en la literatura para determinar variables como el EWT, la cantidad de clorofila a+b (C_{a+b}) y carotenoides (C_{car}).

Tabla 5.7: Índices espectrales medidos (experimentales) versus los índices espectrales simulados. A su vez, se presentan los correspondientes errores experimentales entre los resultados por cada índice y experiencia.

Índices Espectrales Medidos											
Índice	E1 – 02-ene-17			E2 – 18-ene-17			E3 – 07-mar-17				
	P1	P2	P3	P1	P2	P3	P1	P2	P3	P4	P5
I.G.1	1,42	1,52	1,62	0,96	1,00	1,01	0,95	0,91	0,80	0,82	0,81
WI	1,15	1,09	1,11	1,09	1,10	1,08	1,06	1,07	1,06	1,05	1,04
NDVI	0,83	0,82	0,86	0,83	0,84	0,81	0,83	0,81	0,78	0,77	0,79
msR-like	0,80	0,82	0,82	0,69	0,70	0,71	0,70	0,70	0,68	0,69	0,68
I.G.2	0,63	0,65	0,68	0,54	0,55	0,55	0,54	0,54	0,50	0,51	0,51

Índices Espectrales Simulados											
Índice	E1 – 02-ene-17			E2 – 18-ene-17			E3 – 07-mar-17				
	P1	P2	P3	P1	P2	P3	P1	P2	P3	P4	P5
I.G.1	0,92	1,14	0,94	0,81	0,78	0,87	0,91	0,90	0,79	0,88	0,70
WI	1,05	1,04	1,04	1,04	1,04	1,04	1,03	1,03	1,03	1,04	1,04
NDVI	0,86	0,85	0,86	0,84	0,85	0,84	0,84	0,83	0,83	0,80	0,83
msR-like	0,69	0,76	0,69	0,67	0,66	0,69	0,71	0,71	0,67	0,72	0,63
I.G.2	0,56	0,62	0,57	0,54	0,53	0,56	0,58	0,57	0,53	0,57	0,50

Error Experimental (%)											
Índice	E1 – 02-ene-17			E2 – 18-ene-17			E3 – 07-mar-17				
	P1	P2	P3	P1	P2	P3	P1	P2	P3	P4	P5
I.G.1	34,8 %	25,3 %	42,1 %	15,9 %	21,2 %	13,3 %	3,9 %	0,8 %	2,4 %	7,4 %	13,2 %
WI	8,6 %	4,4 %	6,3 %	3,9 %	5,6 %	4,2 %	3,1 %	3,8 %	2,6 %	0,9 %	0,5 %
NDVI	4,0 %	2,7 %	0,4 %	1,6 %	1,2 %	4,2 %	1,2 %	2,3 %	5,9 %	3,4 %	5,2 %
msR-like	13,1 %	7,2 %	15,1 %	3,0 %	5,7 %	3,0 %	1,0 %	0,4 %	1,1 %	5,0 %	6,4 %
I.G.2	10,4 %	3,7 %	16,9 %	0,0 %	4,2 %	1,4 %	7,0 %	5,7 %	6,0 %	12,6 %	2,0 %

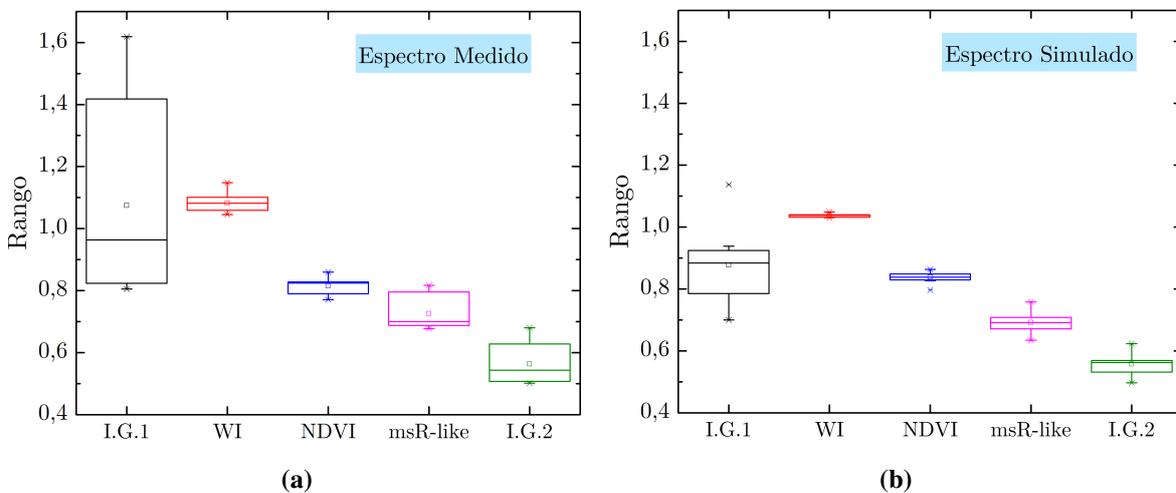
Donde *I.G.1* corresponde al Índice de Gitelson 1 (Gitelson *et al.*, 2003), *WI* corresponde al *Water Index* (Peñuelas *et al.*, 1997), *NDVI* corresponde al *Normalized Difference Vegetation Index* (Rouse *et al.*, 1973), *msR – Like* es el *Modified Simple Ratio – Like* (Datt, 1999b) y, por último, el *I.G.2* corresponde al Índice de Gitelson 2 (Gitelson y Merzlyak, 1994). Por otro lado, E_i (con $i = 1, 2, 3$) corresponde a la experiencia i . En tanto, P_j (con $j = 1, 2, 3, 4, 5$) corresponde a la muestra del pino j .

La media de los errores obtenidos por índice espectral analizado se puede apreciar en la **Tabla 5.8**. En dicha tabla, se aprecian errores por los índices propuestos a partir de un error experimental. Como se puede observar, los mayores errores se obtuvieron para los índices que se han utilizado en la literatura

Tabla 5.8: Valores medios de los errores experimentales por índice espectral analizado.

Índice	Media del error
I.G.1	16,4 %
WI	4,0 %
NDVI	2,9 %
msR-like	5,6 %
I.G.2	6,4 %

para el análisis de pigmentos fotosintéticos tales como la clorofila a+b (C_{a+b}) y carotenoides (C_{car}). De lo anterior resulta interesante analizar el rango de dichos valores, así como la mediana de los datos y los valores máximos y mínimos. Para esto se configuró un diagrama de cajas, que se puede apreciar en la [Figura 5.11](#).

**Figura 5.11:** Gráficos de caja para el análisis de las diferencias entre (a) índices del espectro medido y (b) índices del espectro simulado.

Fuente: Elaboración propia.

A partir de los diagramas de cajas presentes en la [Figura 5.11](#) se puede observar que para el espectro medido ([Figura 5.11a](#)), la mayor variación de los datos se presentó para el Índice de Gitelson 1 (I.G.1). En este, la mediana se ubica en 0,96, mientras que la media equivale a 1,07. El valor máximo de éste índice se aleja bastante del tercer cuartil (límite superior de la caja). Dicho dato, que si bien podría catalogarse como atípico, no lo es puesto que forma parte del último cuartil del diagrama. Por otra parte, en el caso del espectro simulado es también dicho índice el que representa la variación más considerable de valores obtenidos. Sin embargo, en éste último, el valor del dato atípico (que no equivale al mismo pino) se aleja en demasía del grueso de los datos, en donde ya ni siquiera alcanza a ser parte del último cuartil. La relación del error experimental se hace tangible al analizar la variación de los datos a partir de los diagramas de caja. Por otra parte, es interesante analizar el caso del WI, el cual en el espectro simulado se torna con variaciones casi nulas de los datos. En ambos casos la mediana coincide con la media (de 1,08 para el caso del espectro medido y 1,04 para el espectro simulado).

En la [Figura 5.12](#) se pueden apreciar los índices estudiados en la presente sección. Los valores sobre la línea 1:1 representan los índices que fueron sobrestimados por parte de la simulación, mientras que valores bajo la línea representan una subestimación de los datos. Por tanto, se puede apreciar, en general, una tendencia a la subestimación de los valores de los índices, que también se puede observar al contrastar los diagramas de caja presentes en la [Figura 5.11](#). También, la mejor correlación entre los índices fue con el NDVI ($R^2=0,748$).

Un análisis gráfico para la diferencia entre los valores obtenidos del espectro medido y simulado para los índices analizados con anterioridad se puede apreciar en la [Figura 5.13](#).

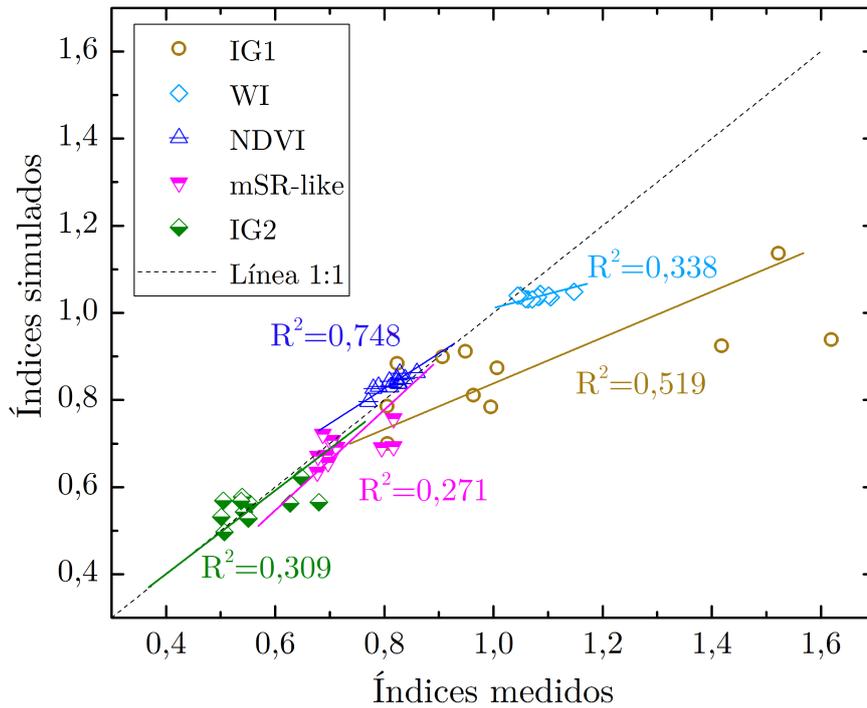


Figura 5.12: Diferencias a partir de la sobre y subestimación de los índices espectrales simulados.
Fuente: Elaboración propia.

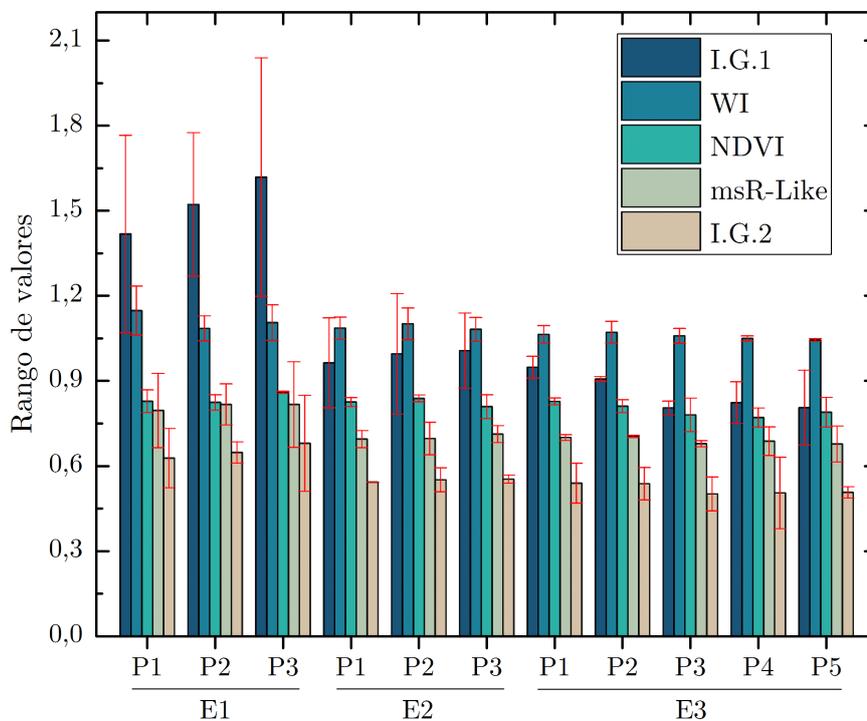


Figura 5.13: Comparación gráfica de los índices medidos versus los simulados. Las barras de error representan el error experimental de los datos obtenidos en la simulación.
Fuente: Elaboración propia.

Del gráfico presente en la [Figura 5.13](#) resulta interesante estudiar las diferencias y semejanzas

entre algunos índices. Se puede apreciar las diferencias en los resultados para el Índice de Gitelson 1 (I.G.1) para ambos espectros, donde en la simulación se obtiene valores bastante menores para el caso de la primera experiencia. Dichas variaciones en la experiencia 1 (E1) representan una media de un 34,1 % de diferencia en los datos del espectro medido y simulado, que corresponden a los mayores errores hallados en la simulación. Luego, estos valores tendieron a ir más acorde a los valores del I.G.1 experimental (espectro medido), en donde la media de las diferencias en la experiencia 2 y experiencia 3 (E2 y E3) equivalen a un 16,8 % y 5,5 %, respectivamente. A raíz de lo anterior, resulta atractivo el comparar los resultados obtenidos en la presente sección con aquellos obtenidos en la sección [Espectros medidos \(Sección 4.1.3\)](#). El Índice de Gitelson 1 utiliza valores de reflectancia (ρ) en los 718 y 775 nm. En el primero de estos valores (ρ_{718}), para ningún espectro medido se pueden visualizar errores significantes asociados a la desviación estándar de los datos. Pero, por el otro lado, para la reflectancia en torno a los 775 nm (ρ_{775}), los errores producto del análisis experimental aumentan (ver [Figura 4.8a](#), [4.9b](#) y [4.10c](#)). Por otra parte, los mayores errores producto de la desviación estándar de los datos se presentan para la experiencia 1, en donde se concentra la mayor diferencia porcentual entre los índices espectrales medidos y simulados. Luego, es posible asociar dicho error a partir de la gran brecha existente entre los espectros obtenidos en la medición del espectro para las muestras.

Por otro lado, para el resto de los índices la brecha de las diferencias entre el espectro medido y simulado es bastante más corta y no se aprecian variaciones significantes. Solo acotar que, al igual que en el caso del I.G.1, el msR-like e I.G.2 también presentaron sus mayores variaciones en la experiencia 1. A su vez, destacar que el WI y el NDVI fueron los índices que tuvieron el menor error experimental, con una media de error de un 4,0 % y 2,9 %, respectivamente.

5.4. Comparación entre índices espectrales y satelitales

Comparar la información multispectral (satelital) con la hiperespectral (simulación con PROSPECT) no es trivial. Hay que recordar que la gran diferencia es que una imagen con valores multispectrales considera rangos de longitudes de ondas i.e. bandas espectrales. Por otro lado, la información hiperespectral considera la reflectancia a determinada longitud de onda que, en el presente proyecto, gracias a la simulación con PROSPECT, considera una resolución espectral de 1 nm. Los resultados de las comparaciones entre los índices espectrales simulados y obtenidos por información satelital (para los mismos 11 índices estudiados por información satelital en la [Sección 4.2](#)) se pueden apreciar en la [Tabla 5.9](#). Los resultados, como se puede apreciar, distan de bastante entre ellos, y la mejor relación fue el NDVI que se explicó con una correlación de un $R^2=0,445$, lo cual dista bastante de una significancia estadística.

En la gráfica presente en la [Figura 5.14](#), se pueden apreciar las diferencias entre los valores de los índices obtenidos a nivel satelital y a nivel hiperespectral. Así, la gran mayoría de los datos tiende a ubicarse bajo la línea 1:1, lo que indica que los valores de los índices a partir de información satelital están subestimando los valores de los índices a nivel hiperespectral, que en rigor son los experimentales (a partir de PROSPECT). En tanto, en la [Figura J.1](#) presente en el [Anexo J](#) se pueden apreciar las variaciones de estos a partir de diagramas de caja.

Así, a partir de la [Figura 5.14](#), la mayor dispersión de los datos se puede apreciar en los valores del RMSI, mientras que la mayor concentración de los datos la presenta el NMDI. Las diferencias se generan por diversas razones. Entre estas, las diferencias entre un sensor satelital que orbita a más de 600 km de altura y la espectral, en donde la información de la vegetación se adquirió simulando PROSPECT con una serie de supuestos asociados y modelos estadísticos, como se estudió en el presente capítulo.

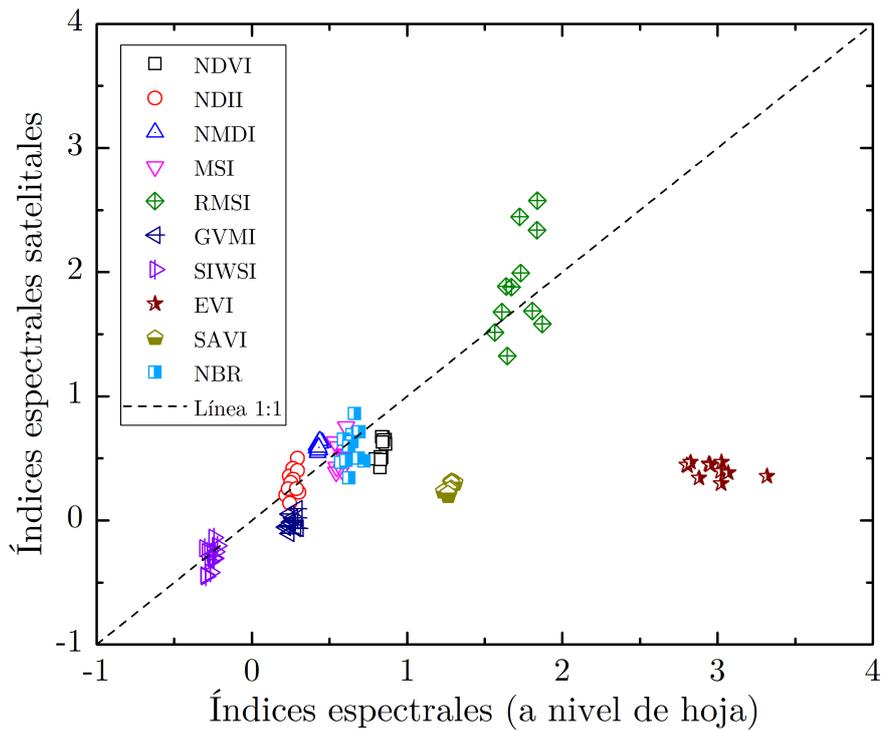


Figura 5.14: Diferencias entre índices a nivel espectral y satelital. Se contrastaron todos los índices a excepción del DDI, que arrojó una subestimación que se alejaba totalmente de la muestra.

Fuente: Elaboración propia.

Tabla 5.9: Relaciones entre información satelital y espectral para mismos índices. Se analizó cada índice que contemplaba como variable dependiente el índice satelital y como independiente el índice espectral (el mismo).

Índice	Ajuste	Satelital			Espectral			R ²
		Media	Mín	Máx	Media	Mín	Máx	
NDVI	Lineal	0,573	0,422	0,671	0,838	0,797	0,863	0,445
NDII	Exponencial	0,308	0,139	0,501	0,264	0,220	0,303	0,208
NMDI	Cuadrático	0,594	0,544	0,640	0,431	0,417	0,455	0,296
MSI	Cuadrático	0,548	0,388	0,755	0,583	0,535	0,639	0,232
RMSI	Exponencial	1,900	1,324	2,576	1,722	1,566	1,871	0,230
GVMI	Cuadrático	0,408	0,297	0,514	0,291	0,242	0,334	0,2815
SIWSI	Cuadrático	-0,303	-0,451	-0,139	-0,264	-0,303	-0,220	0,262
DDI	Cuadrático	0,003	-0,005	0,013	5,362	1,640	8,900	0,256
EVI	Cuadrático	0,408	0,296	0,470	2,969	2,802	3,318	0,253
SAVI	Lineal	0,272	0,196	0,316	1,280	1,234	1,309	0,540
NBR	Exponencial	0,582	0,342	0,860	0,644	0,574	0,724	0,037

NDVI: *Normalized Difference Vegetation Index* (Rouse *et al.*, 1973); NDII: *Normalized Difference Infrared Index* (Hardisky *et al.*, 1983); NMDI: *Normalized Multi-band Drought Index* (Wang y Qu, 2007); MSI: *Moisture Stress Index* (Hunt Jr *et al.*, 2013b); RMSI: *Reciprocal MSI* (Hunt Jr y Rock, 1989; Wang *et al.*, 2013); GVMI: *Global Vegetation Moisture Index* (Ceccato *et al.*, 2002a,b); SIWSI: *Shortwave Infrared Water Stress Index* (Fensholt y Sandholt, 2003); DDI: *Difference Drought Index* (Gulácsi y Kovács, 2015); EVI: *Enhanced Vegetation Index* (Huete *et al.*, 2002); SAVI: *Soil Adjusted Vegetation Index* (Huete, 1988); NBR: *Normalized Burn Ratio* (Key y Benson, 2002), (FYI, NBR utilizado fue: $(B5-B7)/(B5+B7)$).

6 | Estimación del contenido de humedad (FMC)

El objetivo principal del presente trabajo consiste en analizar la factibilidad de emplear la información multispectral e híperespectral como herramientas para una estimar, indirectamente, el contenido de humedad como porcentaje de la biomasa. De esta forma, el análisis recae en la obtención del FMC (*Fuel Moisture Content*). Este estudio se focalizó en los combustibles vivos, dado que son estos quienes desarrollan los incendios más desastrosos, impredecibles y catastróficos (McAllister *et al.*, 2012; Yebra *et al.*, 2013). Como mencionan McAllister *et al.* (2012) en su estudio, muy poco se conoce sobre combustibles vivos y, de hecho, por décadas éstos han sido tratados como combustibles muertos “húmedos”, enfatizando en que poco y nada se ha hecho para justificar lo anterior. A su vez, en el mismo artículo, el FMC explicó entre el 74–80 % del tiempo de ignición (tiempo que demora la vegetación en lograr la ignición ante determinado flujo de calor incidente – Drysdale, 2011, Cap. 6).

Burgan y Rothermel (1984) establecen que el FMC de vegetación viva es usualmente utilizado para predecir el riesgo de incendios, debido a que la cantidad de agua (EWT) por unidad de materia seca (DMC) son variables críticas tanto para la ignición como para la propagación en modelos de predicción del riesgo de incendios. Otros autores determinan que el FMC, en conjunto con el viento, es uno de los factores principales que afectan el comportamiento del fuego (Burgan, 1987; Simard y Main, 1982; Viney y Hatton, 1989). Por último, también existen autores que se han esmerado por intentar calcular éste parámetro desde información satelital (Chuvieco *et al.*, 2002; Danson y Bowyer, 2004; Wang *et al.*, 2013).

De esta forma, se aprecia el poder que tiene esta variable y la importancia de su estudio para la gestión del riesgo en materia de incendios forestales. Los incendios son sucesos que no se pueden controlar, pero se puede establecer un plan de riesgo en función del FMC. Lo que se propone en el presente proyecto, si bien se enfoca en un solo tipo de vegetación, es un modelo que puede ser investigado aún más, con instrumentos más precisos, y para muchas especies de tanto bosque nativo como plantaciones no-nativas (como lo es el caso de la especie bajo estudio). A continuación se presentarán los modelos asociados a la estimación indirecta del FMC a partir de espectrometría (del espectro simulado por PROSPECT) y de información satelital.

6.1. FMC por espectrometría

En este caso se busca determinar el FMC a partir de expresiones para el EWT y DMC a nivel de hoja (EWT_{Leaf} y DMC_{Leaf}), a continuación se presentará el estudio de cada caso por separado y se concluirá con la intersección de ambos para la estimación indirecta del FMC a partir de índices híperespectrales.

6.1.1 EWT por espectrometría

En el caso del *Equivalent Water Thickness*, se estudió la mejor correlación entre sus valores obtenidos en laboratorio y 13 índices espectrales hallados en la literatura. Cada uno de los índices se calculó a partir de los resultados del espectro simulado por PROSPECT en el Capítulo 5. Los resultados de los índices versus el EWT medido en laboratorio (a partir de su coeficiente de correlación), se puede apreciar en la Tabla 6.1.

Tabla 6.1: Correlaciones para el EWT_{Leaf} a partir de índices espectrales del espectro simulado.

Índice	Abreviación	Ajuste [†]	R ²	Autor
Normalized Difference Infrared Index	NDII	P	0,5709	Hardisky <i>et al.</i> (1983)
Normalized Multi-band Drought Index	NMDI	L	0,8722	Wang y Qu (2007)
Moisture Stress Index	MSI	E	0,5602	Hunt Jr y Rock (1989)
Normalized Difference Vegetation Index	NDVI	L	0,2291	Rouse <i>et al.</i> (1973)
Reciprocal of Moisture Stress Index	RMSI	P	0,5492	Hunt Jr y Rock (1989)
Global Vegetation Moisture Index	GVMi	P	0,5813	Ceccato <i>et al.</i> (2002b)
Shortwave Infrared Water Stress Index	SIWSI	E	0,5521	Fensholt y Sandholt (2003)
Enhanced Vegetation Index	EVI	P	0,3071	Huete <i>et al.</i> (2002)
Normalized Burn Ratio	NBR	P	0,2876	Key y Benson (2002)
Water Index	WI	L	0,8694	Peñuelas <i>et al.</i> (1997)
Normalized Difference Water Index	NDWI	L	0,7209	Gao (1996)
Normalized Difference Tillage Index	NDTI	P	0,1332	Van Deventer <i>et al.</i> (1997)
Simple Ratio Water Index	SRWI	L	0,7215	Zarco-Tejada <i>et al.</i> (2003)

[†]P = Potencial, L = Lineal, E = Exponencial.

De esta forma, se aprecia que los mejores resultados son del NMDI ($R^2=0,8722$), el WI ($R^2=0,8694$), el NDWI ($R^2=0,7234$) y el SRWI ($R^2=0,7215$); todos con $R^2>0,72$. Sobre estos, claramente el mejor es el NMDI, lo cual no va de la mano con lo que se contaba como hipótesis, dado que se esperaba que el NDWI y el WI tendrían las mejores correlaciones por lo recopilado de la literatura.

El NDMI es un índice que fue elaborado por Wang y Qu (2007), cuyo objetivo es analizar la humedad se los suelos y de la vegetación a partir de información satelital. Éste índice se calcula como:

$$NMDI = \frac{\rho_{860nm} - (\rho_{1640nm} - \rho_{2130nm})}{\rho_{860nm} + (\rho_{1640nm} - \rho_{2130nm})}$$

Donde ρ_{860} , ρ_{1640} y ρ_{2130} corresponden a la reflectancia a los 860, 1.640 y 2.130 nm. Similar al caso del NDWI y del NDII, éste índice utiliza el canal centrado a los 860 nm, el cual es insensible a los cambios en el contenido de agua de la vegetación, pero a diferencia del NDWI o del NDII, el NMDI utiliza la diferencia (pendiente) de dos bandas de absorción del agua centradas en los 1.640 y 2.130 nm (Wang y Qu, 2007). En la Figura 6.1 se pueden apreciar los gráficos de regresión para los 4 mejores índices.

Luego, el modelo a utilizar para determinar, indirectamente, el valor del EWT a nivel de hoja (EWT_{Leaf}) es:

$$EWT_{Leaf} = 0,48151 \cdot NMDI - 0,18383 \left(\frac{g}{cm^2} \right) \quad (6.1)$$

Por otro lado, se calcula el error medio cuadrático ($RMSE_{EWT}$) para el modelo a partir de la expresión 6.2.

$$RMSE_{EWT} = \sqrt{\frac{1}{n} \sum_{i=1}^n (EWT_i - EWT_{Mi})^2} = 0,001899 \left(\frac{g}{cm^2} \right) \quad (6.2)$$

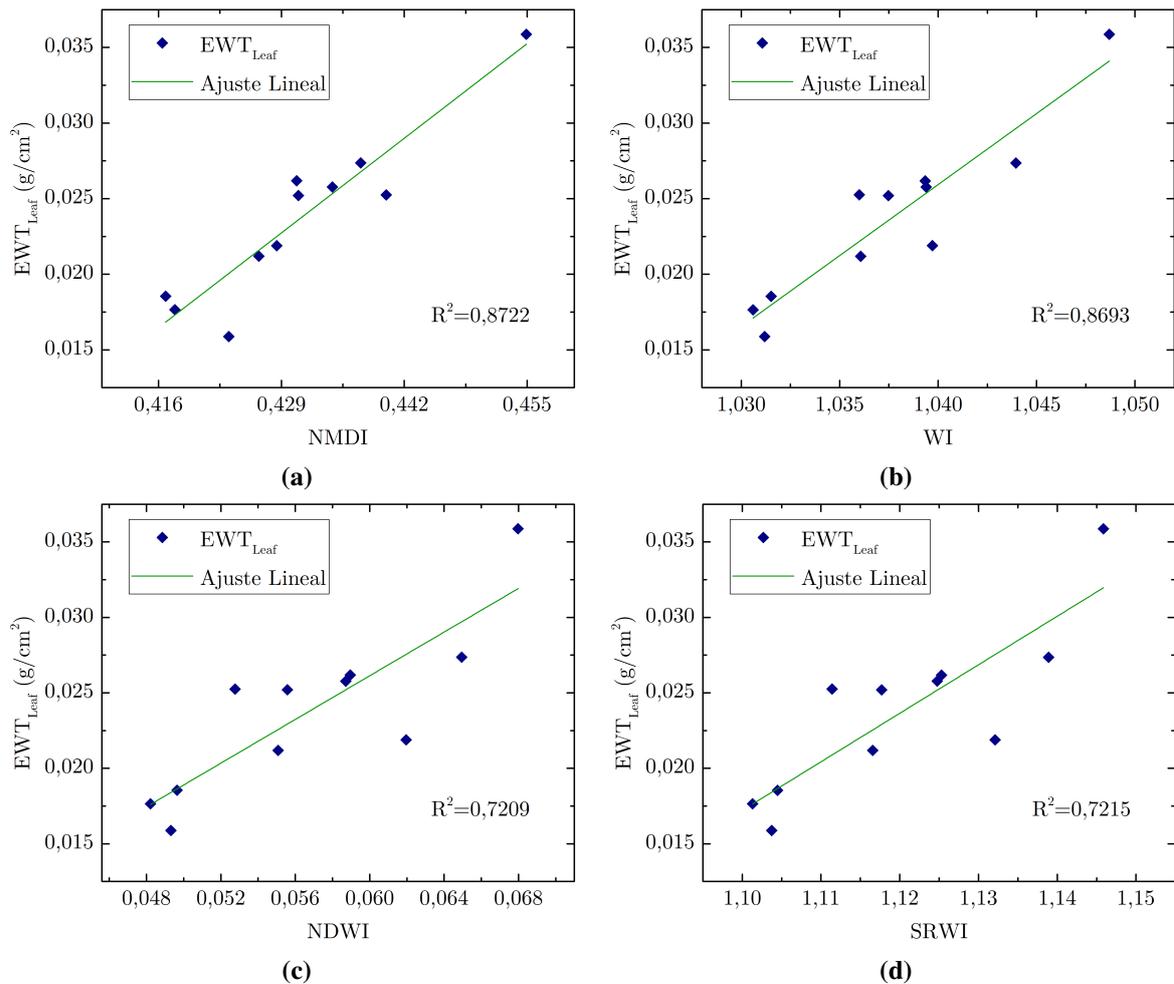


Figura 6.1: Gráficos de correlaciones para el EWT_{Leaf} versus (a) el *Normalized Multi-band Drought Index*, (b) el *Water Index*, (c) el *Normalized Difference Water Index* y (d) el *Simple Ratio Water Index*.

Fuente: Elaboración propia.

6.1.2 DMC por espectrometría

La forma para determinar el DMC_{Leaf} a partir de espectrometría sigue la misma metodología que el EWT_{Leaf}. La diferencia es que, para este caso (y pensando que los resultados iban a ser peores que para el caso del EWT_{Leaf}) se probaron más de 20 índices espectrales y su relación con el DMC_{Leaf}. Los resultados, que contemplan la correlación (R²) y el ajuste realizado, se pueden apreciar en la [Tabla 6.2](#).

Lo que resulta interesante de los resultados es que la mayor correlación que logró el DMC_{Leaf} fue con el WI. En base a lo recopilado de la literatura, se esperaba que la mejor correlación fuese con índices creados para estimar la materia seca. Tal es el caso de índices como el NDMI, CAI, NDLI, LCA, SINDRI, entre otros, que han sido utilizados para determinar la materia seca ([Hunt Jr et al., 2013](#)). Por otro lado, cabe destacar que algunos de los índices nombrados anteriormente se crearon para determinar la materia seca de muestras muertas, cuyo caso no es el del presente estudio. La gran sorpresa en estos resultados son por parte del NDWI y del WI, que, de hecho, tuvieron mejores resultados con el DMC_{Leaf} que con el EWT_{Leaf}. Así, se puede determinar que los índices creados para estimar el contenido de humedad tuvieron, a su vez, buenos resultados con el DMC para el estudio en cuestión. Lo anterior se puede deber a dos puntos: primero, a que se está analizando la materia seca de muestras vivas y, segundo, se realiza la hipótesis que al parecer la estructura interna de la especie *pinus radiata* juega un rol fundamental en la forma en la que ésta puede almacenar el agua, puesto que inclusive la materia seca se pudo correlacionar bien con índices que se han utilizado, hace

ya bastantes años, para determinar el contenido de humedad por unidad de área (EWT). Como no se encontró literatura en relación a estudios del DMC_{Leaf} en especies coníferas no se puede corroborar lo mencionado anteriormente, pero se cree que en base a estos índices (WI, NMDI, NDWI) es posible obtener, indirectamente, la cantidad de materia seca por unidad de área de coníferas como el *pinus radiata*.

Tabla 6.2: Correlaciones para el DMC_{Leaf} a partir de índices espectrales.

Índice	Abreviación	Ajuste [†]	R ²	Autor
Normalized Difference Vegetation Index	NDVI	L	0,1425	Rouse <i>et al.</i> (1973)
Normalized Difference Infrared Index	NDII	L	0,6222	Hardisky <i>et al.</i> (1983)
Normalized Multi-band Drought Index	NMDI	L	0,8431	Wang y Qu (2007)
Moisture Stress Index	MSI	E	0,6742	Hunt Jr y Rock (1989)
Reciprocal of Moisture Stress Index	RMSI	L	0,6151	Hunt Jr y Rock (1989)
Global Vegetation Moisture Index	GVMI	L	0,6324	Ceccato <i>et al.</i> (2002b)
Shortwave Infrared Water Stress Index	SIWSI	E	0,6685	Fensholt y Sandholt (2003)
Difference Drought Index	DDI	E	0,0794	Gulácsy y Kovács (2015)
Enhanced Vegetation Index	EVI	L	0,2306	Huete <i>et al.</i> (2002)
Normalized Burn Ratio	NBR	E	0,3817	Key y Benson (2002)
Water Index	WI	L	0,9334	Peñuelas <i>et al.</i> (1997)
Dry Matter Content Index*	DMCI	C	0,0616	Romero <i>et al.</i> (2012)
Normalized Difference Water Index	NDWI	L	0,8368	Gao (1996)
Normalized Dry Matter Index	NDMI	E	0,1104	Wang <i>et al.</i> (2011a,b)
Normalized Difference Tillage Index	NDTI	E	0,2095	Van Deventer <i>et al.</i> (1997)
Cellulose Absorption Index	CAI	E	0,0327	Nagler <i>et al.</i> (2000)
Normalized Difference Lignin Index	NDLI	E	0,2258	Serrano <i>et al.</i> (2002)
Normalized Difference Nitrogen Index	NDNI	E	0,2938	Serrano <i>et al.</i> (2002)
Ligno-Cellulose Absorption Index	LCA	C	0,0113	Daughtry <i>et al.</i> (2005)
Shortwave Infrared Norm. Diff. Residue Index.	SINDRI	E	0,0449	Serbin <i>et al.</i> (2009)
Simple Ratio Water Index	SRWI	L	0,8375	Zarco-Tejada <i>et al.</i> (2003)

[†] C = Cuadrático, L = Lineal, E = Exponencial.

* Éste índice no tiene nombre por el autor, se le agregó por facilidad.

Lo que si se establece en la literatura es sobre la relación de las curvas de absorción tanto del agua como de materia seca. Como el índice WI de (Peñuelas *et al.*, 1997) es de la forma:

$$WI = \frac{\rho_{900}}{\rho_{970}} = \frac{\rho_{insensible}}{\rho_{sensible}}$$

Se podría determinar, según el estudio realizado por Mobasheri y Fatemi (2013), que probablemente en la región de los 970 nm existe una mayor absorción de materia seca que de agua en ésta especie conífera; que se puede inferir del corolario que plantean Riaño *et al.* (2005) en el ámbito de que el DMC es más difícil de obtener al momento de invertir PROSPECT que el EWT, donde concluyen que se debe, probablemente, por los altos coeficientes de absorción del agua que enmascaran los efectos de la respuesta espectral de la materia seca, caso que aquí no dio (todo lo contrario), dado que el WI tuvo mejor correlación con la materia seca i.e. se cree que una banda sensible a la materia seca rondaría los 970 nm. A su vez, cabe destacar que la gran mayoría de los índices se han creado a partir de LOPEX93, en cuyos datos no se encuentran muestras vivas de vegetación conífera, sino de vegetación con hojas de tipo latifoliada.

Las gráficas de los mejores cuatro resultados obtenidos para el DMC_{Leaf} se pueden apreciar en la Figura 6.2. Luego, el índice que se propone utilizar para elaborar la estimación indirecta del DMC_{Leaf} es el *Water Index*, que tuvo la mayor correlación ($R^2=0,9334$). El modelo propuesto es:

$$DMC_{Leaf} = 0,6998 \cdot WI - 0,7086 \left(\frac{g}{cm^2} \right) \quad (6.3)$$

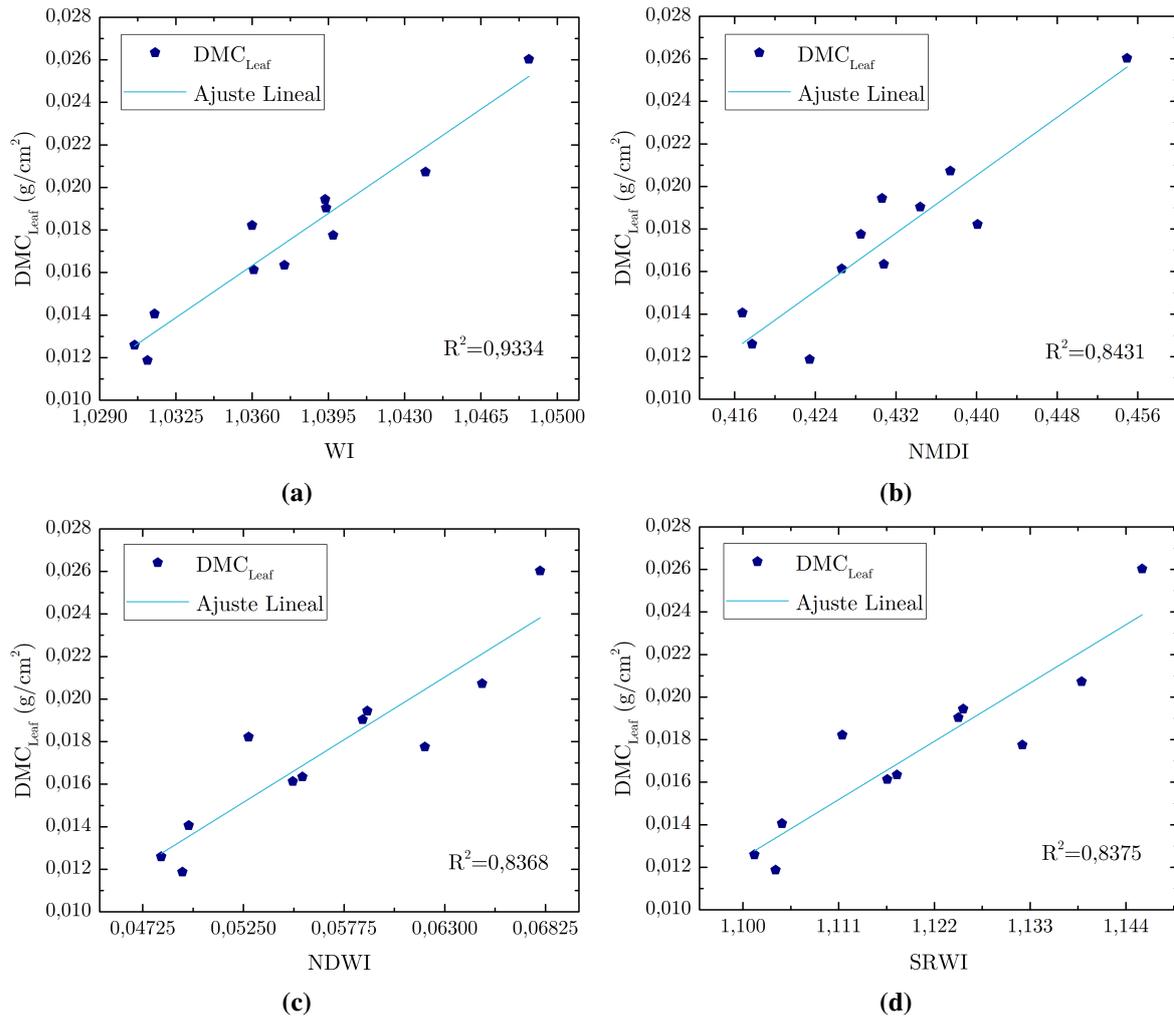


Figura 6.2: Gráficos de correlaciones para el DMC_{Leaf} versus (a) el *Water Index*, (b) el *Normalized Multi-band Drought Index*, (c) el *Normalized Difference Water Index* y (d) el *Simple Ratio Water Index*.

Fuente: Elaboración propia.

El error medio cuadrático ($RMSE_{DMC_{Leaf}}$) del modelo y su fórmula se pueden apreciar en la ecuación (6.4), donde DMC_i y DMC_{Mi} corresponden a los valores del DMC medidos en laboratorio (DMC_{Leaf}) y aquel obtenido por el modelo, respectivamente.

$$RMSE_{DMC_{Leaf}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (DMC_i - DMC_{Mi})^2} = 0,000988 \left(\frac{g}{cm^2} \right) \quad (6.4)$$

6.1.3 FMC a partir de espectrometría

En base a los resultados obtenidos anteriormente, es posible generar un modelo para determinar el FMC. Primero, recordando el cómo se calcula el FMC, se tiene:

$$FMC = \frac{EWT}{DMC} \cdot 100 \%$$

Reemplazando el EWT y el DMC por los respectivos modelos determinados en la ecuación (6.1) y (6.3), respectivamente, se tiene que el modelo para estimar, indirectamente, el FMC por espectrometría (FMC_e) es:

$$\left[FMC_e = \frac{0,48151 \cdot NMDI - 0,18383}{0,6998 \cdot WI - 0,7086} \cdot 100 (\%) \right] \quad (6.5)$$

Aplicando el modelo (6.5) con los índices obtenidos (del WI y NMDI) se procede a calcular el error medio cuadrático del FMC tanto medido ($RMSE_{FMC_{Medido}}$) como el aplicado con la metodología del cociente entre el EWT_{Leaf} y DMC_{Leaf} ($RMSE_{FMC_{Metodología}}$), presente en las ecuaciones (6.6) y (6.7).

$$RMSE_{FMC_{Medido}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (FMC_{Medido} - FMC_{Mi})^2} = 14,20 \% \quad (6.6)$$

$$RMSE_{FMC_{Metodología}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (FMC_{Metodología} - FMC_{Mi})^2} = 13,73 \% \quad (6.7)$$

Donde FMC_{Medido} , $FMC_{Metodología}$ y FMC_{Mi} corresponden a los valores del FMC medido en laboratorio, obtenido en la metodología del cociente entre el EWT_{Leaf} con el DMC_{Leaf} y del modelo, respectivamente.

De esta forma, es posible dar cuenta que los resultados, en primera instancia, no están del todo lejano a los valores reales del FMC medido para éste primer caso que consistió en utilizar índices a partir de información espectral. También se corroboró lo que se pensó en primera instancia, los errores asociados a la metodología fueron menores a los errores asociados a la obtención del FMC medido, a partir de la comparación de los correspondientes RMSE.

Sin embargo, si bien los errores medios cuadráticos no fueron tan elevados, aún así cabe destacar casos particulares dentro de los resultados y estudiar un tanto más a fondo el resultado de dichos valores. Para una comparación visual se elaboró el gráfico de cajas presente en la Figura 6.3, el cual da a conocer las comparaciones entre los rangos de los resultados obtenidos para tanto el FMC medido, el FMC por la metodología del cociente entre el EWT_{Leaf} con el DMC_{Leaf} y el FMC del modelo de la ecuación (6.5).

En la Sección 4.1.2 ya se establecieron las diferencias entre el FMC_{Medido} y $FMC_{Metodología}$. De esta forma, a continuación se comparará el FMC_e (modelo) con los nombrados anteriormente. En primer lugar, para determinar las variaciones de los errores experimentales se establece:

$$Error_{FMC_{Medido}} = \frac{|FMC_{Medido} - FMC_e|}{FMC_{Medido}} \quad (6.8)$$

$$Error_{FMC_{Metodología}} = \frac{|FMC_{Metodología} - FMC_e|}{FMC_{Metodología}} \quad (6.9)$$

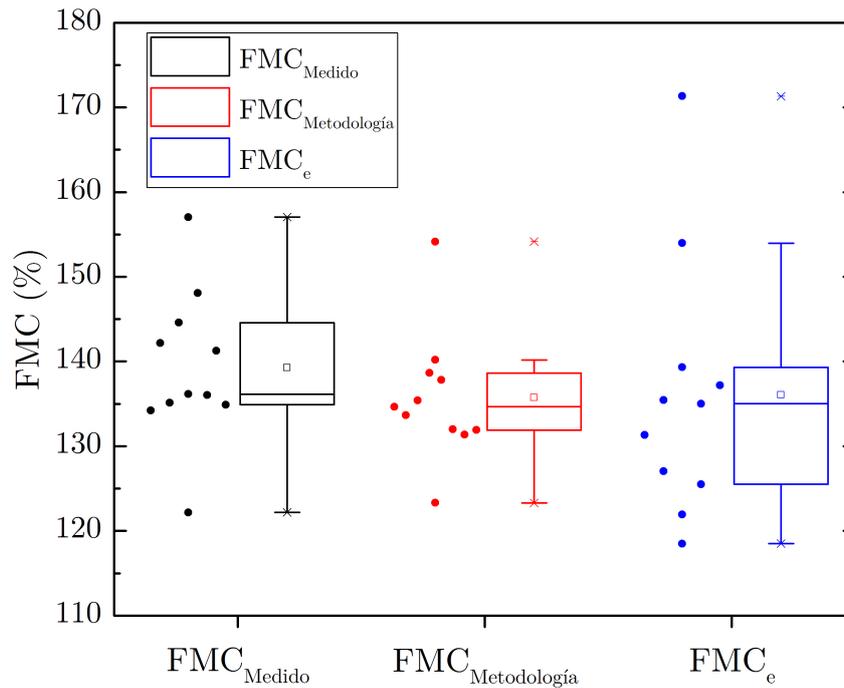


Figura 6.3: Diagrama de caja de la variación del FMC del modelo elaborado por espectrometría en comparación al FMC_{Medido} y $FMC_{Metodología}$.

Fuente: Elaboración propia.

A su vez, y con el fin de no confundir al lector con tanta nomenclatura, se definen dos casos de comparación, que se aprecian en la [Tabla 6.3](#).

Tabla 6.3: Síntesis de casos para la comparación de resultados del FMC_e .

Caso	Comparación
Caso 1	FMC_{Medido} versus FMC_e
Caso 2	$FMC_{Metodología}$ versus FMC_e

De esta forma, para el caso 1 los errores variaron desde un 0,86 % hasta un 18,50 %, con una media de 8,23 %. En tanto, para el caso 2 los errores variaron desde un 0,04 % hasta un 23,58 %, con una media de 6,95 %. A partir del diagrama de cajas presente en la [Figura 6.3](#), se tiene que el 50 % de los datos del FMC_e se concentran en la caja entre los 125,51 % a los 139,31 %. La mediana de los datos no es centrada, por lo que se está en presencia de asimetría en los datos (que se puede apreciar en la dispersión al lado izquierdo de la caja, que corresponden a los puntos obtenidos en el modelo). El valor que adquiere la mediana es de 135,01 % y, por ende, los datos tienden hacia la parte superior de la caja i.e. al tercer cuartil. En tanto, la media obtenida equivale a 136,05 %. Si se comparan los resultados anteriores con los casos, se tiene que para el caso 1, la mediana varió un -1,14 %. Para el caso 2, la variación de la mediana es de 0,34 %. Para la media, en el caso 1 la variación fue de -3,2 % mientras que para el caso 2 fue de 0,31 %. Luego, se aprecia que las variaciones tanto de la media como de la mediana de los datos fue prácticamente nula. Ahora bien, se aprecia para los datos del modelo una mayor dispersión de los datos. De hecho, existe un valor atípico, que equivale a 171,32 %. Este valor representó el máximo error en ambos casos (caso 1 y caso 2). El diagrama de cajas lo consideró atípico debido a que el valor se encuentra por sobre el 1,5 de la diferencia entre el tercer y primer cuartil más el valor máximo, cuyo valor equivale a 160,02 %. Así, cualquier valor por sobre dicho número se considera como atípico.

A partir del diagrama de cajas presente en la [Figura 6.3](#) se pueden extraer una serie de conclusiones que tienen relación con la variabilidad del modelo con respecto a los datos obtenidos de forma experimental. Dicha variación se puede apreciar en la [Figura 6.4](#), en donde se contrastan los valores del modelo (FMC_e) con respecto al FMC medido en el laboratorio y el FMC obtenido a partir de la metodología del cociente entre el EWT_{Leaf} y el DMC_{Leaf} . La línea que divide el gráfico en dos partes es una línea 1:1, por ende lo ideal sería que los datos del modelo se ajustasen lo más posible a dicha recta. A priori, es complejo determinar si el modelo sobre o subestimó los valores experimentales del FMC, pero si se puede apreciar que, para cada caso, existe una alta dispersión de los datos, que es lo que también se puede apreciar en el diagrama de cajas elaborado con anterioridad. En tanto, los valores del FMC metodológico (puntos verdes) tienden a colocarse sobre la línea 1:1, por lo que se puede establecer que el modelo se ajusta de mejor forma a dichos valores experimentales, que se condice con los resultados hallados al obtener los errores medios cuadráticos (RMSE), donde éstos son menores para el caso del FMC obtenido a partir de la metodología.

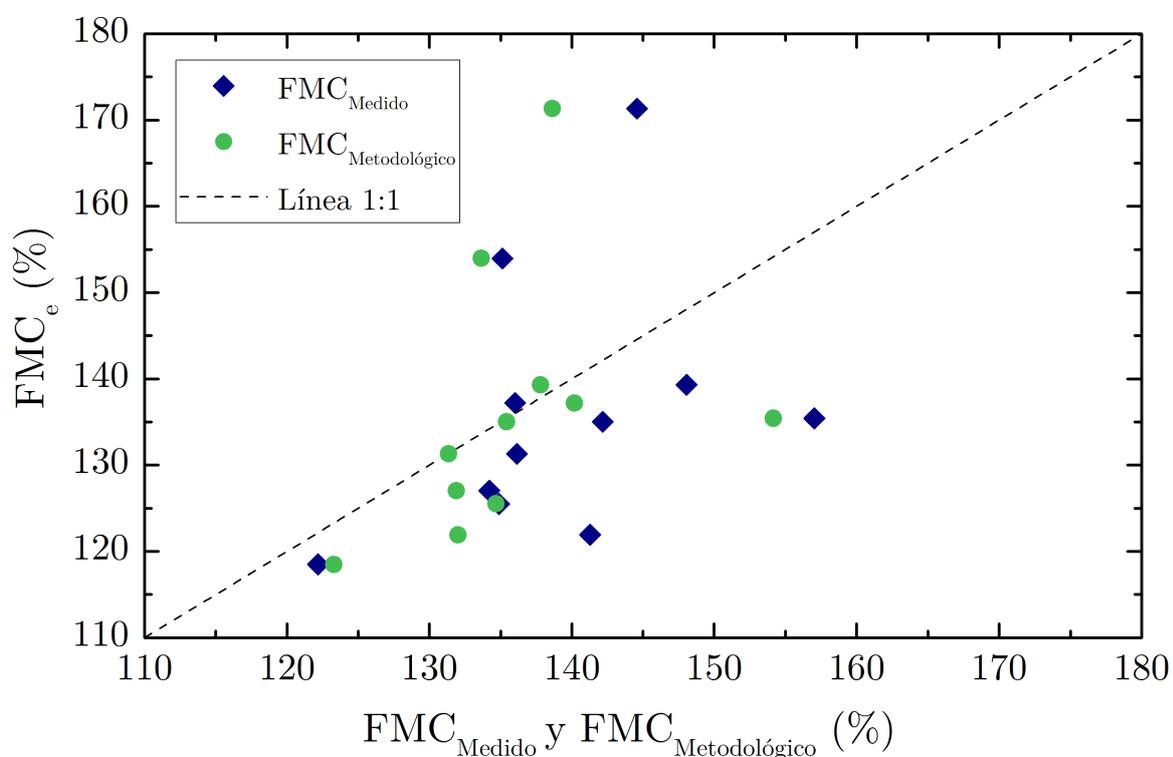


Figura 6.4: Variación del modelo para estimar el FMC por espectrometría con respecto a los datos obtenidos experimentalmente.

Fuente: Elaboración propia.

Los resultados fueron bastante mejor de lo esperado, pero cabe destacar que el modelo de una u otra forma sobrestimó los escenarios, lo que se aprecia claramente en una mayor dispersión de los datos (ver [Figura 6.3](#)), que se puede apreciar en datos, para ambos casos, por sobre la línea 1:1 en las gráficas presentes en la [Figura 6.4](#).

6.2. FMC por información satelital

Al igual que en el caso de la elaboración del modelo para estimar el FMC por espectrometría a partir del EWT y DMC a nivel de hoja, se procederá a analizar el modelo para el caso del EWT_{Canopy} como para del DMC_{Canopy}.

Es importante destacar que el FMC a nivel de hoja y a nivel de dosel es, en rigor, el mismo valor. Al multiplicar por el factor LAI se amplifica, por dicha variable, tanto el EWT_{Leaf} como el DMC_{Leaf}, multiplicando por una suerte de “uno conveniente” (ver ecuación 4.4) que se asemeja mejor a los valores del EWT y DMC vistos desde el cielo (por un sensor satelital). Luego de estimar el FMC, se calculará su error comparándolo, al igual que en el caso del FMC por espectrometría, con el FMC_{Medido} y FMC_{Metodología}.

La obtención de cada índice espectral estudiado se genera luego de calibrar la imagen en valores de reflectancia a nivel del suelo. Así, con una matemática de bandas, se pueden obtener los valores de los índices a nivel satelital. Para cada índice existe, entonces, una imagen asociada que contendrá valores de aquel índice. Para la extracción de los valores se colocaron sobre la imagen los puntos de recolección de las muestras y se extraen, uno a uno, los valores asociados a cada píxel de la imagen en donde hubo recolección de muestras, que contendrá la información del índice bajo estudio.

6.2.1 EWT_{Canopy} por información satelital

Los resultados del EWT_{Canopy} se pueden apreciar en la Sección 4.2.3. Se estudió la mejor relación entre los valores obtenidos del EWT a nivel del dosel y 10 índices espectrales que se estudiaron con anterioridad para estimar el FMC por información hiperespectral. Los resultados de los índices estudiados, el correspondiente ajuste realizado y la correlación (R^2) se puede apreciar en la Tabla 6.4.

Tabla 6.4: Correlaciones para el EWT_{Canopy} a partir de índices espectrales a nivel satelital.

Índice	Abreviación	Ajuste [†]	R ²	Autor
Normalized Difference Vegetation Index	NDVI	E	0,6684	Rouse <i>et al.</i> (1973)
Normalized Difference Infrared Index	NDII	E	0,8371	Hardisky <i>et al.</i> (1983)
Normalized Multi-band Drought Index	NMDI	P	0,4742	Wang y Qu (2007)
Moisture Stress Index	MSI	E	0,6759	Hunt Jr y Rock (1989)
Reciprocal of Moisture Stress Index	RMSI	P	0,6705	Hunt Jr y Rock (1989)
Global Vegetation Moisture Index	GVMi	P	0,6810	Ceccato <i>et al.</i> (2002b)
Shortwave Infrared Water Stress Index	SIWSI	E	0,7299	Fensholt y Sandholt (2003)
Enhanced Vegetation Index	EVI	E	0,5044	Huete <i>et al.</i> (2002)
Normalized Burn Ratio	NBR	E	0,6148	Key y Benson (2006)
Soil Adjusted Vegetation Index	SAVI	L	0,5243	Huete (1988)

[†] P = Potencial, L = Lineal, E = Exponencial.

A partir de la Tabla 6.4, se obtiene que las mayores correlaciones fueron con el NDII ($R^2=0,8371$) y con el SIWSI ($R^2=0,7299$), índices que se han elaborado, justamente, para estimar, indirectamente, el contenido de humedad de la vegetación. Especialmente el caso del NDII elaborado por Hardisky *et al.* (1983), que se elaboró, justamente, para determinar la humedad a nivel del dosel con información satelital. Las gráficas de dichos índices, con el EWT_{Canopy} como variable dependiente, se pueden apreciar en la Figura 6.5.

De esta forma, el índice candidato (mayor R^2) para estimar el EWT_{Canopy} es el NDII. Su ecuación se presenta en la expresión (6.10).

$$NDII = \frac{\rho_{850} - \rho_{1650}}{\rho_{850} + \rho_{1650}} \quad (6.10)$$

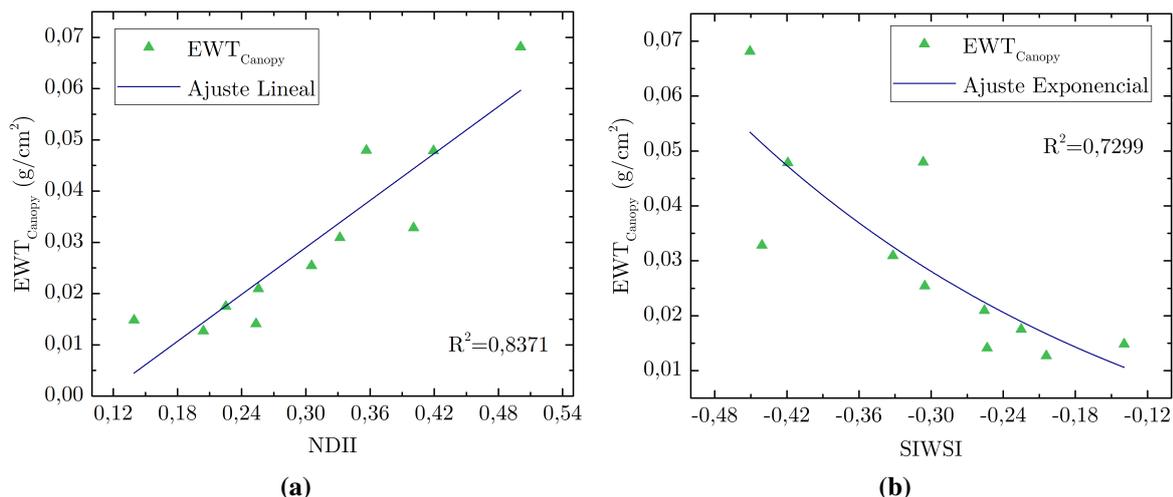


Figura 6.5: Gráficos de regresión para el EWT_{Canopy} versus el NDII (a) y SIWSI (b) a nivel satelital. **Fuente:** Elaboración propia.

Donde ρ_{850} y ρ_{1650} son los valores de reflectancia a los 850 y 1.650 nm. De esta forma, es posible dar cuenta que, como ya se estableció en el [Estado del Arte \(Capítulo 2\)](#), el presente índice contiene las regiones del NIR (una banda insensible a la absorción de agua) y el SWIR (una banda sensible al contenido de agua de la vegetación). Éste índice se construyó de la siguiente forma para las imágenes capturadas por el sensor OLI del satélite Landsat 8:

$$NDII_{L8} = \frac{(B5 - B6)}{(B5 + B6)} \quad (6.11)$$

Donde la B5 y la B6 son la Banda 5 y la Banda 6 de las imágenes del satélite Landsat 8 (L8). La banda 5 es la que se determina como la banda del NIR (*Near Infrared*) y comprende los 851 – 879 nm. En tanto, la banda 6 es la denominada banda SWIR-1 (*Shortwave Infrared*), que comprende los 1.566 – 1.651 nm ([USGS, 2015a](#)). Para poder obtener su rango de valores, se calibró la imagen satelital (tal y como se explicó en el [Capítulo 4](#)) y luego, a través de una matemática de bandas, se obtuvo el índice deseado.

Así, el modelo propuesto para determinar el EWT_{Canopy} en función del NDII se presenta en la ecuación (6.12).

$$EWT_{Canopy} = 0,1527 \cdot NDII - 0,0168 \left(\frac{g}{cm^2} \right) \quad (6.12)$$

Luego, el error medio cuadrático (RMSE_{EWT_C}) y su fórmula se pueden apreciar en la ecuación (6.13), donde EWT_{C_i} y EWT_{m_i} corresponden al EWT a nivel del dosel (que se determinó al multiplicar el EWT_{Leaf} por el LAI – ver [Sección 4.2.3](#)) y al EWT obtenido por el modelo en función del NDII como variable independiente, respectivamente.

$$RMSE_{EWT_C} = \sqrt{\frac{1}{n} \sum_{i=1}^n (EWT_{C_i} - EWT_{m_i})^2} = 0,00682 \left(\frac{g}{cm^2} \right) \quad (6.13)$$

6.2.2 DMC_{Canopy} por información satelital

Los índices que se pueden calcular para estimar, indirectamente, el DMC_{Canopy} son bastante menos que para el caso del DMC_{Leaf}. Esto porque hay que recordar que se está trabajando con bandas del espectro, y por lo tanto existe una limitación, dado que la región óptica del sensor OLI del satélite Landsat 8 contempla 7 bandas. A diferencia del EWT, el DMC a nivel del dosel es bastante más complejo debido a que las curvas de absorción del agua son, en gran parte, mayores que las de la absorción de materia seca. De esta forma, los índices que se calcularon para el DMC_{Canopy} fueron 5. Los resultados que involucran el ajuste y la correlación de los índices en función del DMC_{Canopy} se puede apreciar en la [Tabla 6.5](#).

Tabla 6.5: Correlaciones para el DMC_{Canopy} a partir de índices espectrales a nivel satelital.

Índice	Abreviación	Ajuste [†]	R ²	Autor
Normalized Multi-band Drought Index	NMDI	E	0,4401	Wang y Qu (2007)
Global Vegetation Moisture Index	GVMi	E	0,6593	Ceccato <i>et al.</i> (2002b)
Shortwave Infrared Water Stress Index	SIWSI	E	0,7144	Fensholt y Sandholt (2003)
Normalized Burn Ratio	NBR	L	0,8356	Key y Benson (2006)
Difference Drought Index	DDI	C	0,2305	Gulácsi y Kovács (2015)

[†] C = Cuadrático, L = Lineal, E = Exponencial.

A partir de la [Tabla 6.5](#), se obtiene que las mayores correlaciones fueron con el NBR ($R^2=0,8356$) y con el SIWSI ($R^2=0,7144$), que a diferencia del caso de la sección anterior, estos índices no fueron creados para determinar, indirectamente, el DMC_{Canopy}. Ahora bien, surge un índice que se creía podía tener buenos resultados y en rigor lo tuvo. Tal es el caso del NBR, el cual se ha utilizado como índice espectral para determinar la severidad de un incendio ([Veraverbeke *et al.*, 2010b](#)). De esta forma, se cree que podría tener una relación con la determinación de la materia seca observada desde una plataforma satelital. Las gráficas de dichos índices, con el DMC_{Canopy} como variable dependiente, se pueden apreciar en la [Figura 6.6](#).

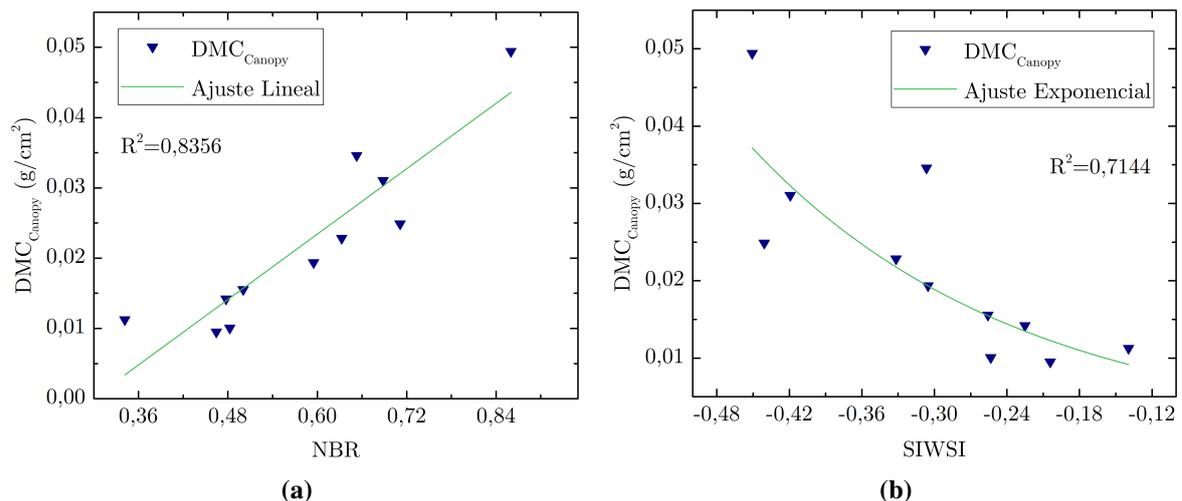


Figura 6.6: Gráficos de regresión para el DMC_{Canopy} versus el NBR (a) y SIWSI (b) a nivel satelital.

Fuente: Elaboración propia.

De esta forma, el índice candidato para estimar, indirectamente, el DMC_{Canopy} es el NBR. La fórmula para calcular dicho índice se puede apreciar en la ecuación (6.14) ([Veraverbeke *et al.*, 2010a](#)).

$$NBR = \frac{(NIR - MIR)}{(NIR + MIR)} \quad (6.14)$$

Donde NIR y MIR son las regiones del infrarrojo cercano y del infrarrojo medio, respectivamente. En tanto, llevando éstas regiones del espectro a bandas del sensor OLI del satélite Landsat 8, se tiene la fórmula presente en la ecuación (6.15).

$$\text{NBR}_{L8} = \frac{(B5 - B7)}{(B5 + B7)} \quad (6.15)$$

Donde B5 y B7 son la Banda 5 y la Banda 7 de las imágenes capturadas por el sensor OLI del satélite Landsat 8 (L8). Como se dijo con anterioridad, la banda 5 es la denominada banda del NIR y comprende los 851 – 879 nm. En tanto, la banda 7 es la denominada banda SWIR-2 (*Shortwave Infrared*) que se ubica en la región del MIR entre los 2.110 – 2.290 nm (USGS, 2016). Así, el modelo que se establece para estimar el $\text{DMC}_{\text{Canopy}}$ mediante el NBR como variable independiente se puede apreciar en la ecuación (6.16).

$$\text{DMC}_{\text{Canopy}} = 0,0775 \cdot \text{NBR} - 0,0231 \left(\frac{\text{g}}{\text{cm}^2} \right) \quad (6.16)$$

En tanto, también se calculó el error medio cuadrático del modelo ($\text{RMSE}_{\text{DMC}_c}$). El resultado y su fórmula se pueden apreciar en la ecuación (6.17), donde DMC_{C_i} y DMC_{m_i} corresponden al DMC a nivel del dosel (que se determinó al multiplicar el DMC_{Leaf} por el LAI – ver Sección 4.2.3) y al DMC obtenido por el modelo en función del NBR de la ecuación (6.16), respectivamente.

$$\text{RMSE}_{\text{DMC}_c} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{DMC}_{C_i} - \text{DMC}_{m_i})^2} = 0,00477 \left(\frac{\text{g}}{\text{cm}^2} \right) \quad (6.17)$$

6.2.3 FMC a partir de información satelital

En base a los resultados obtenidos con anterioridad es posible generar un modelo para determinar, indirectamente, el FMC a partir de índices espectrales a nivel satelital. El FMC se calcula como:

$$FMC = \frac{EWT_{Canopy}}{DMC_{Canopy}} \cdot 100 \%$$

Luego, si se reemplazan el EWT y el DMC por los modelos determinados en las ecuaciones (6.12) y (6.16), respectivamente, se tiene que:

$$\left[FMC_s = \frac{0,1527 \cdot NDII - 0,0168}{0,0775 \cdot NBR - 0,0231} \cdot 100(\%) \right] \quad (6.18)$$

A partir del modelo planteado en la ecuación (6.18) con tanto el NDII y NBR obtenidos, se procede a calcular el error medio cuadrático del FMC medido ($RMSE_{FMC_{Medido}}$) y del FMC que contempla la metodología del cociente entre el EWT_{Leaf} y DMC_{Leaf} ($RMSE_{FMC_{Metodología}}$), presentes en las ecuaciones (6.19) y (6.20).

$$RMSE_{FMC_{Medido}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (FMC_{Medido} - FMC_s)^2} = 10,80 \% \quad (6.19)$$

$$RMSE_{FMC_{Metodología}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (FMC_{Metodología} - FMC_s)^2} = 8,50 \% \quad (6.20)$$

Donde FMC_{Medido} , $FMC_{Metodología}$ y FMC_s corresponden a los valores del FMC medido en laboratorio, obtenida en la metodología del cociente entre el EWT_{Leaf} con el DMC_{Leaf} y del modelo, respectivamente.

Al igual que el modelo del FMC por espectrometría, los errores medios cuadráticos obtienen su menor valor al relacionar el FMC satelital (FMC_s) con el FMC obtenido de la metodología ($FMC_{Metodología}$), lo cual también era de esperar, ya que es con dicha metodología (que al final de cuentas es el cociente entre el EWT y DMC a nivel de hojas y se escala amplificando por el LAI al nivel del dosel) que se obtiene el modelo para tanto el EWT_{Canopy} como DMC_{Canopy} .

En este caso, y sorpresivamente, los errores medios cuadráticos obtuvieron un menor valor que en el caso hiperespectral. Sin embargo, también existen algunos datos que son interesantes de analizar. Para una comparación visual de la variación de los resultados obtenidos se elaboró el gráfico de cajas presente en la Figura 6.7, que presenta las variaciones entre los rangos de los resultados obtenidos para tanto el FMC_{Medido} , el $FMC_{Metodología}$ y el FMC obtenido por el modelo de la ecuación (6.18) (FMC_s).

En la Sección 4.1.2 se establecieron las diferencias entre el FMC_{Medido} y $FMC_{Metodología}$. De esta forma, a continuación se comparará el FMC_s (modelo) con los nombrados anteriormente. En primer lugar, para determinar las variaciones de los errores experimentales se establecen las ecuaciones (6.21) y (6.22).

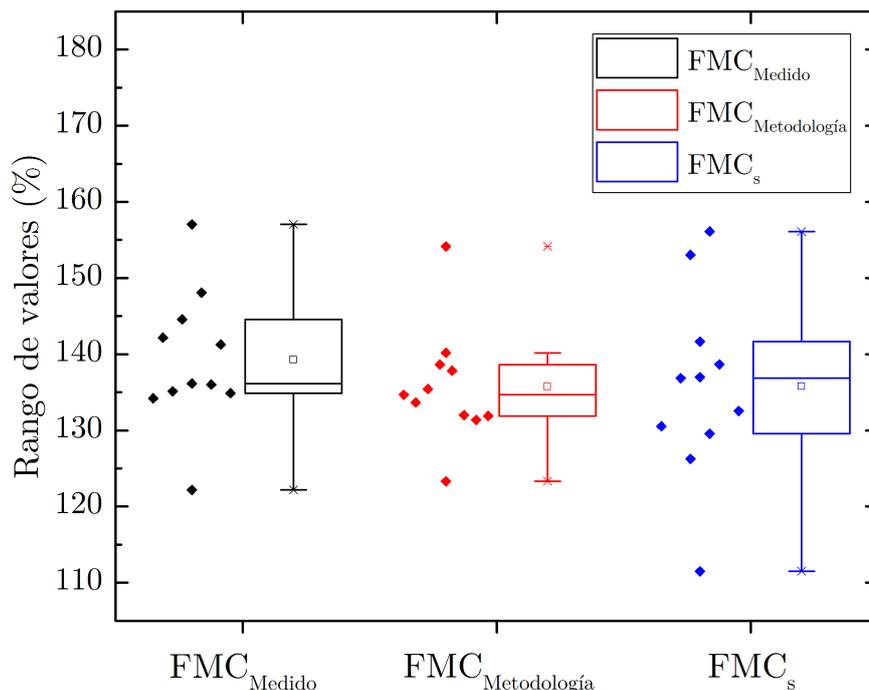


Figura 6.7: Diagrama de caja de la variación del FMC del modelo elaborado por información satelital en comparación al FMC_{Medido} y $FMC_{Metodología}$. Cabe destacar que FMC_s es el FMC del modelo presente en la ecuación (6.18) i.e. el modelo del FMC a nivel satelital.

Fuente: Elaboración propia.

$$\text{Error } FMC_{Medido} = \frac{|FMC_{Medido} - FMC_s|}{FMC_{Medido}} \quad (6.21)$$

$$\text{Error } FMC_{Metodología} = \frac{|FMC_{Metodología} - FMC_s|}{FMC_{Metodología}} \quad (6.22)$$

Con el fin de no confundir al lector con nomenclaturas, se definen los mismos dos casos que se analizaron para el FMC por espectrometría, que se pueden apreciar en la [Tabla 6.6](#).

Tabla 6.6: Síntesis de casos para la comparación de resultados del FMC_s .

Caso	Comparación
Caso 1	FMC_{Medido} versus FMC_s
Caso 2	$FMC_{Metodología}$ versus FMC_s

De esta forma, para el caso 1 los errores variaron desde un 0,59 % hasta un 17,50 %, con una media de 6,17 %. En el caso 2 los errores variaron desde un 0,48 % hasta un 16,59 %, con una media de 4,27 %. A partir del diagrama de cajas presente en la [Figura 6.7](#), el rango de valores que adquiere el modelo (FMC_s) varía entre 111,49 % y 156,11 %, donde el 50 % de los datos se concentran en la caja entre los 129,56 % y 141,66 %. La mediana de los datos no es centrada, por lo que existe asimetría en los datos (que se puede apreciar en la dispersión al lado izquierdo de la caja, que corresponden a los puntos obtenidos en el modelo). El valor que adquiere la mediana es de 136,86 % y, por ende, los datos tienden hacia la parte superior de la caja i.e. al tercer cuartil. En tanto, la media obtenida equivale a 135,79 %. Si se comparan los resultados anteriores con los casos (ver [Tabla 6.6](#)), se tiene que para

el caso 1, la mediana del FMC_s varió un +0,71 %. Para el caso 2, la variación de la mediana fue de +2,19 %. Para la media, en el caso 1 la variación fue de -3,46 % mientras que para el caso 2 fue de +0,06 %. Luego, se aprecia que las variaciones tanto de la media como de la mediana de los datos fue prácticamente nula. Cabe destacar que no se presentan datos atípicos en el modelo del FMC_s .

Al igual que en el caso del modelo elaborado para determinar el FMC por información espectral, a partir del diagrama de cajas presente en la Figura 6.7 se pueden extraer una serie de conclusiones que tienen relación con la variabilidad del modelo con respecto a los datos obtenidos de forma experimental. Dicha variación se puede apreciar en la Figura 6.8, en donde se contrastan los valores del modelo (FMC_s) con respecto al FMC medido en el laboratorio y el FMC obtenido a partir de la metodología del cociente entre el EWT_{Leaf} y el DMC_{Leaf} . La línea que divide el gráfico en dos partes es una línea 1:1, por ende lo ideal sería que los datos del modelo se ajustasen lo más posible a dicha recta. En este caso también los datos tienden a una mayor dispersión, pero los círculos verdes ($FMC_{Metodología}$) tienden a ubicarse más cerca de la línea 1:1 que los rombos azules (FMC_{Medido}), que se corrobora con el hecho de que el modelo con respecto al FMC metodológico obtuvo un menor RMSE.

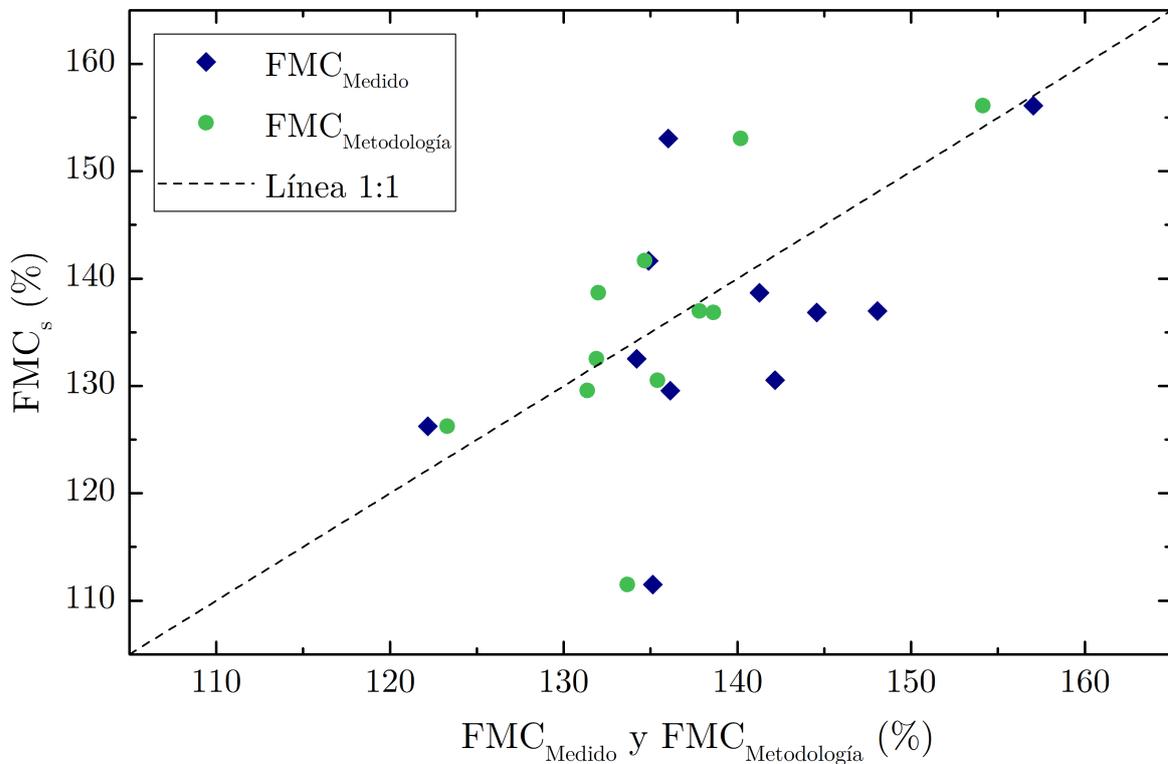


Figura 6.8: Variación del modelo para estimar el FMC por información satelital con respecto a los datos obtenidos experimentalmente.

Fuente: Elaboración propia.

Los resultados fueron bastante mejor de lo esperado, inclusive mejor que por el lado espectral, pero cabe destacar que el modelo de una u otra forma subestimó los valores experimentales.

6.3. Contraste entre modelos obtenidos

En la presente sección se procederá a comparar los modelos en base a los resultados obtenidos previamente. En primer lugar, el rango de valores obtenidos se graficó a partir de diagramas de cajas para ambos modelos y para tanto el FMC medido como metodológico, que se puede apreciar en la Figura 6.9.

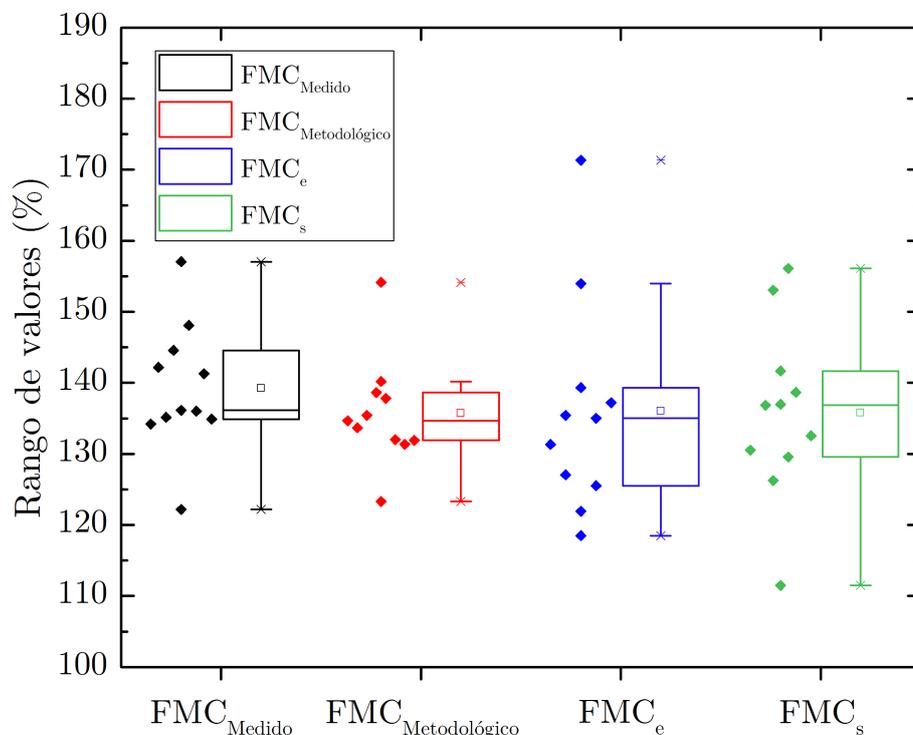


Figura 6.9: Comparación del rango de valores obtenidos para los modelos y los valores experimentales del FMC.

Fuente: Elaboración propia.

Por otra parte, se elaboró el gráfico presente en la Figura 6.10 que contiene los valores de los respectivos modelos y los valores de tanto el FMC medido como metodológico con una línea 1:1, que es la unión entre los gráficos que se presentaron en las figuras 6.4 y 6.8.

De esta forma, es fácil dar cuenta que ambos modelos elaborados para estimar el FMC tendieron a generar una mayor dispersión de los datos experimentales. Pero en rigor su variación es muy pequeña (notar la escala de valores en el eje de las abscisas), lo que da indicio de que en realidad los resultados son una buena primera aproximación al problema de la determinación del FMC indirectamente.

Pareció interesante aplicar el modelo del FMC_s para estimar el FMC_e, en donde se requieren los valores del NDII y NBR a nivel hiperespectral. Cabe destacar que no se puede evaluar al revés i.e. aplicar el modelo del FMC_e para estimar el FMC_s, dado que el modelo del FMC_e involucra índices a nivel hiperespectral como el WI, que no es factible determinarlo a partir de información satelital. No obstante, hay que obtener las longitudes de onda para las cuales se obtendrán los valores de reflectancia del NBR, dado que es un índice que se construyó para información satelital (bandas espectrales) y no para información hiperespectral. Así, se debe incurrir en supuestos para determinarlo a nivel hiperespectral. Recordando la ecuación del NBR, se tiene que:

$$NBR_{L8} = \frac{(NIR - MIR)}{(NIR + MIR)} \quad (6.23)$$

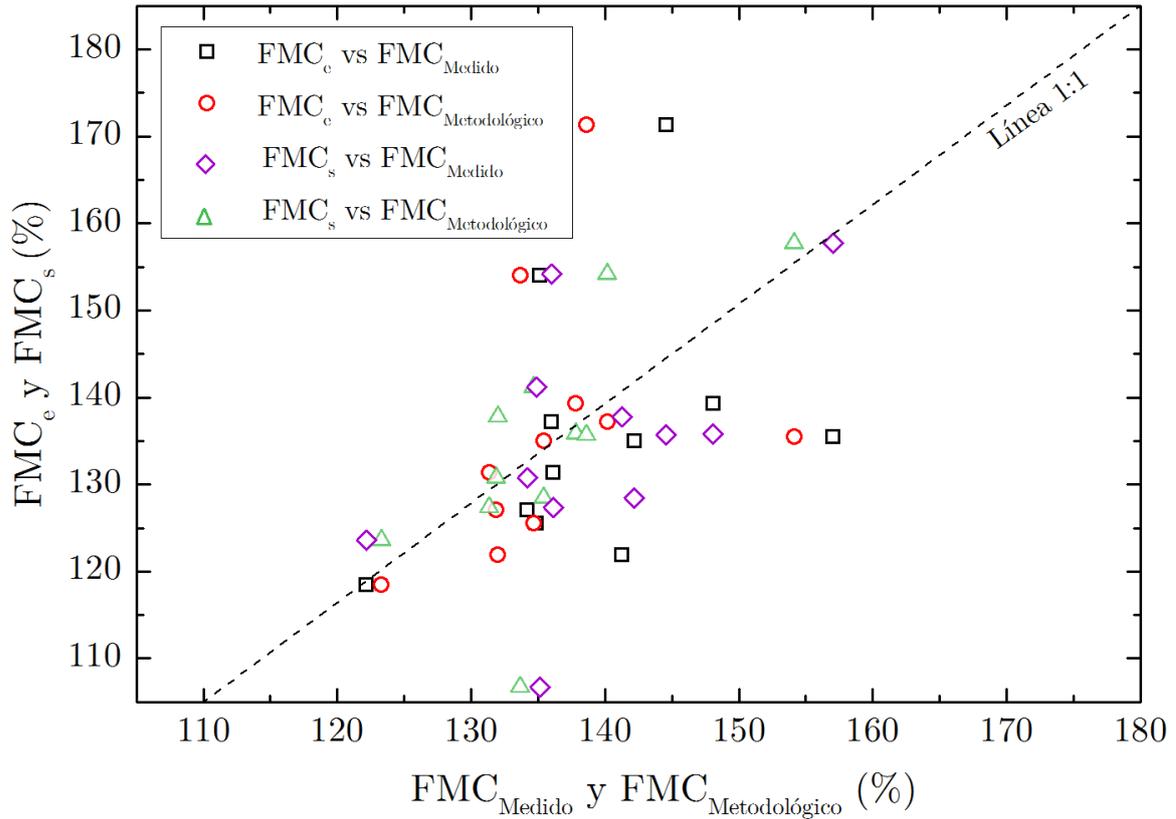


Figura 6.10: Comparación de las variaciones de los modelos con respecto a los valores experimentales del FMC.

Fuente: Elaboración propia.

Luego, si esos los valores del NIR y MIR se llevan a las bandas del sensor OLI del satélite Landsat 8, se tiene que:

$$NBR_{L8} = \frac{(B5 - B7)}{(B5 + B7)} \quad (6.24)$$

Donde B5 y B7 son la Banda 5 y la Banda 7 del sensor OLI, cuyas variaciones son entre los 851 – 879 nm y los 2.110 – 2.290 nm, respectivamente. De esta forma, el primer NBR que se propone (NBR_{S1}) es aquel que considera los valores medios de cada rango de las bandas anteriormente mencionadas. Así, se tiene que:

$$NBR_{S1} = \frac{(\rho_{865} - \rho_{2200})}{(\rho_{865} + \rho_{2200})} \quad (6.25)$$

De donde ρ_{865} y ρ_{2200} corresponden a los valores de reflectancia a los 865 y 2.200 nm, respectivamente, que son los puntos medios de las bandas 5 y 7 del sensor OLI, que corresponde a la forma en la cual se obtuvo el NBR como índice hiperespectral en la Sección 6.1. Luego, la segunda forma que se propone para obtener los valores de reflectancia a nivel hiperespectral con el NBR son mediante el promedio del rango de reflectancias entre las longitudes de onda de las bandas del sensor OLI, tal como se presente en la ecuación (6.26).

$$NBR_{S2} = \frac{\bar{\rho}(851 - 879) - \bar{\rho}(2110 - 2290)}{\bar{\rho}(851 - 879) + \bar{\rho}(2110 - 2290)} \quad (6.26)$$

De donde $\bar{\rho}(851 - 879)$ y $\bar{\rho}(2110 - 2290)$ corresponden a los valores de la reflectancia promedio en los intervalos de 851–879 nm y 2.110–2.290 nm, respectivamente.

Así, las ecuaciones (6.25) y (6.26) ingresan al modelo del FMC_s , donde se generan dos fórmulas para calcular el FMC por cada uno de estos (con el NDII constante a nivel híperespectral) a partir de la expresión (6.18). De esta forma, se producen los siguientes modelos:

$$FMC_{e_1} = \frac{0,1527 \cdot NDII - 0,0168}{0,0775 \cdot NBR_{S1} - 0,0231} \cdot 100(\%) \quad (6.27)$$

$$FMC_{e_2} = \frac{0,1527 \cdot NDII - 0,0168}{0,0775 \cdot NBR_{S2} - 0,0231} \cdot 100(\%) \quad (6.28)$$

Donde FMC_{e_1} y FMC_{e_2} son las fórmulas para estimar, mediante el modelo elaborado para estimar el FMC a nivel satelital (FMC_s), los valores del FMC a nivel híperespectral con los índices propuestos para el FMC a nivel satelital respectivo al NBR.

La relación entre el FMC_{e_1} y FMC_{e_2} fue casi perfecta ($R^2=0,98$), lo que indica que las variaciones del NBR se comportaron con bastante similitud en cuanto a magnitud, pero los rangos que abarcaron cada uno difieren. La Figura 6.11 presenta los diagramas de caja para representar el rango de variación entre los resultados obtenidos de las ecuaciones (6.27) y (6.28).

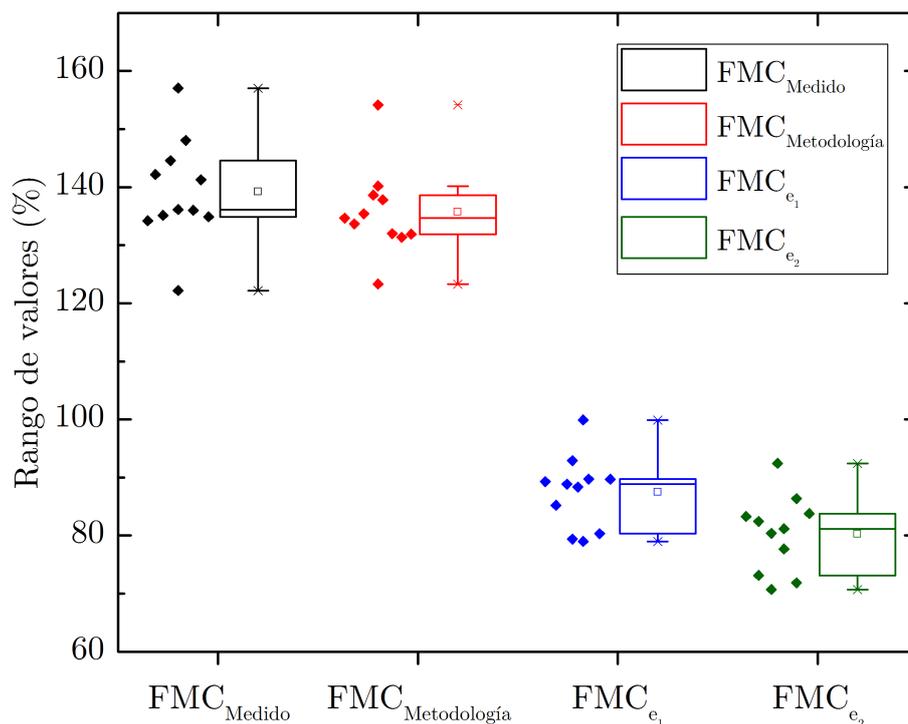


Figura 6.11: Diagramas de caja de la variación del FMC aplicando el modelo del FMC_s a los datos híperespectrales.

Fuente: Elaboración propia.

A partir de la Figura 6.11 es posible dar cuenta de que los rangos varían considerablemente con respecto a los datos experimentales i.e. FMC medido y FMC metodológico. Para el caso del FMC_{e_1} , su variación fue entre los 78,99 % y los 99,90 %, con una media de 87,51 % y mediana de 88,84 %. En el segundo caso (FMC_{e_2}) la variación fue entre los 70,70 % y los 92,43 %, con una media de 80,29 % y

mediana de 81,17 %. En ambos casos la mediana tendió a la parte superior de la caja, por lo que se presenta asimetría en los datos y una mayor concentración del grueso de estos hacia el tercer cuartil. En tanto, a partir de la [Figura 6.12](#) se puede apreciar notoriamente la subestimación de los datos experimentales por parte de ambos modelos generados con respecto al FMC medido y metodológico, ya que todos los datos se ubican bajo la recta 1:1.

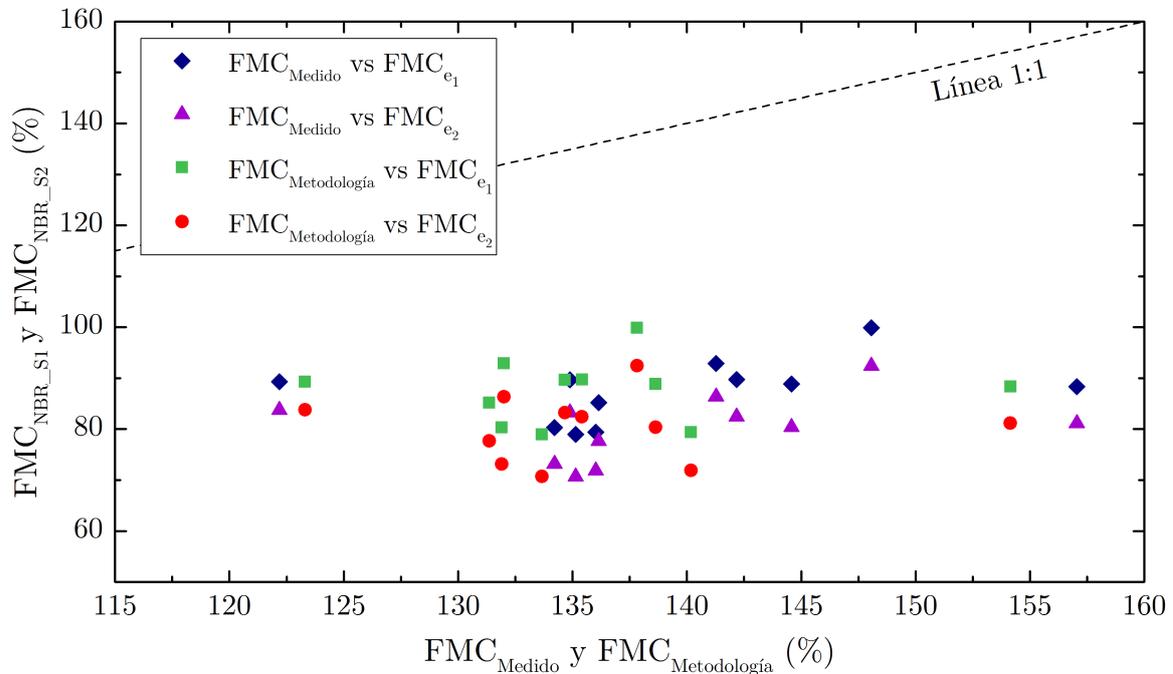


Figura 6.12: Gráfica de subestimación de los valores experimentales por parte de los modelos del FMC al aplicar el modelo del FMC_s a nivel híperespectral.

Fuente: Elaboración propia.

Por otra parte, también se estudiaron los errores medios cuadráticos para cada caso. Es decir, se calculó el RMSE del FMC medido en comparación al FMC_{e1} y FMC_{e2} , como también se calculó el RMSE del FMC metodológico con respecto al FMC_{e1} y FMC_{e2} . La fórmula para el cálculo del RMSE es:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (FMC_{exp.} - FMC_m)^2} \quad (\%) \quad (6.29)$$

Donde $FMC_{exp.}$ corresponde a los valores experimentales del FMC (medido o metodológico) y FMC_m corresponde a los valores del FMC de los modelos elaborados con anterioridad (FMC_{e1} y FMC_{e2}). Los resultados se pueden apreciar en la [Tabla 6.7](#).

Tabla 6.7: Escenarios a estudiar para los RMSE de los modelos del FMC_s aplicado a información híperespectral.

Escenario	RMSE
FMC_{Medido} y FMC_{e1}	52,41 %
FMC_{Medido} y FMC_{e2}	59,63 %
$FMC_{Metodología}$ y FMC_{e1}	49,09 %
$FMC_{Metodología}$ y FMC_{e2}	56,28 %

A partir de los resultados expuestos en la [Tabla 6.7](#) se puede dar cuenta de que los menores errores también correspondieron a los modelos al compararlos con el FMC metodológico. Ahora bien, el mejor resultado, mínimo RMSE, se dio con la primera metodología para calcular el NBR i.e. el punto céntrico de la correspondiente banda utilizada por el sensor OLI para calcular el índice.

Los resultados demuestran que es bastante complejo realizar una metodología en la que el modelo del FMC por información satelital se utilice a nivel híperespectral para estimar dicha variable. Las variaciones fueron sustanciales y los datos fueron, para todos los casos subestimados.

Discusión

Los resultados determinaron que el FMC puede ser estimado con cierta rigurosidad y criterio a partir de espectrometría e información satelital. La metodología empleada creó cierta dependencia con los modelos, dado que el cociente entre el EWT y DMC a nivel de hoja (que es el FMC que se le atribuyó el nombre de $FMC_{\text{Metodología}}$) determinaron el cálculo del FMC a partir de la metodología del secado de la muestras en el horno adquirido de una aguja de pino representativa de la muestra (que se analizó mediante el estudio del promedio de 10 agujas “representativas” de la muestra). Luego, al comparar dicho valor con el FMC medido a la muestra completa (FMC_{Medido}), existieron variaciones en los resultados. La relación entre el FMC y el cociente entre el EWT_{Leaf} y DMC_{Leaf} se explicó linealmente con una correlación de $R^2=0,76$, donde el $FMC_{\text{Metodológico}}$ tendió a subestimar los valores del FMC_{Medido} . A partir de lo anterior, se le otorga el error a la cantidad de muestras “representativas” que se seleccionaron. Se estima que con una mayor cantidad de agujas (>10 agujas) esta diferencia disminuiría.

En cuanto a la determinación del FMC a partir de espectrometría, se propone el NMDI (Wang y Qu, 2007) como índice espectral para estimar, indirectamente, el contenido de humedad por unidad de área a nivel de hoja (EWT_{Leaf}), cuya relación fue lineal con una correlación de $R^2=0,87$ y un RMSE de $0,001899$ (g/cm^2). Para el caso del DMC_{Leaf} , la mejor relación se obtuvo con el *Water Index* (WI – Peñuelas *et al.*, 1997), donde los datos se correlacionaron con un $R^2=0,93$ y un RMSE de $0,000988$ (g/cm^2). Por otro lado, los resultados obtenidos para el EWT resultaron bastante coherentes con lo hallado en la literatura. De esta forma se estima que los índices que se han utilizado ampliamente para determinar, indirectamente, el EWT para vegetación con tipo de hoja latifoliada sirven para determinar la misma variable en vegetación conífera. Sin embargo, la estimación del DMC por parte del WI es un tanto extraño en comparación a lo hallado en la literatura, dado que por lo general el DMC obtiene mejores resultados con índices como el DMCI, NDMI, CAI, entre otros. Se cree que lo anterior se debe a la estructura interna de la vegetación bajo estudio (*pinus radiata*), que difiere de vegetación con hojas de tipo latifoliadas. En la literatura no se halló estudios en coníferas que determinaran índices para estimar el DMC, por lo que no hay una base comparativa para los resultados en esta materia. De esta forma, se cree que en este tipo de vegetación (coníferas) es probable que en regiones del espectro cercanas a los 970 nm (banda sensible del WI) pueda existir, a priori, una mayor absorción de materia seca que agua, pero afirmarlo en su totalidad sería erróneo, debido a que también el WI tuvo buenos resultados con el EWT a nivel de hoja. Por ende, faltaría más información para poder concluir con certeza.

El FMC estimado tanto “medido” como “metodológico” obtuvieron un RMSE de $14,20\%$ y $13,73\%$, respectivamente, donde se puede apreciar mejores resultados al comparar los datos con el FMC metodológico. Así, existe una mayor dependencia de los resultados a la metodología propuesta, que abarca desde el sector electo, la vegetación de estudio, la temperatura y tiempo de secado en el horno, la metodología para determinar el espectro reflectivo con el sol como fuente de luz, la determinación del peso fresco y seco de una aguja de pino, los estimación de los parámetros de entrada de PROSPECT a partir de modelos de regresión a la base de datos LOPEX93, entre otras. Por último, se puede determinar que el modelo para la estimación del FMC a partir de espectrometría (FMC_e) condujo a una mayor dispersión de los datos con respecto al FMC medido y el FMC metodológico, donde se ajustó de mejor forma a al último, que se ve representado, a su vez, por el menor RMSE obtenido.

Por otro lado, para la estimación del FMC a partir de información satelital, se propone el NDII como índice espectral con el objeto de estimar, indirectamente, el EWT a nivel del dosel, cuya relación fue de $R^2=0,8371$ y el RMSE del modelo fue de $0,00682$ (g/cm^2). En tanto, se propone el NBR como índice espectral para estimar, indirectamente, el DMC a nivel del dosel, cuya relación fue de $R^{0,8356}$ y el RMSE del modelo fue de $0,00477$ (g/cm^2). En el caso del FMC, los resultados obtenidos

del RMSE indican que, al igual que en el caso espectral, los errores fueron menores al comparar el modelo con el FMC metodológico ($FMC_{\text{Metodología}}$), cuyos resultados fueron de 10,80 % y 8,50 % para el caso del RMSE del modelo para el FMC medido en laboratorio y el FMC metodológico, respectivamente. En tanto, se puede determinar que el modelo para la estimación del FMC a partir de índices satelitales (FMC_s) tuvo una tendencia a la dispersión los datos con respecto al FMC medido y el FMC metodológico, donde se ajustó de mejor forma a al último, que se corrobora con un menor valor del RMSE obtenido. En la literatura se hallaron estudios como el de Wang *et al.* (2013) que utilizan el índice NDII para estimar el contenido de humedad por unidad de área (EWT) o directamente el FMC, pero no se encontró estudios que utilizaran el NBR como índice para estimar, indirectamente, el DMC. Éste índice se creó con la finalidad de determinar zonas quemadas por incendios forestales y cuyos resultados han sido bastante buenos como lo demuestran el estudio de Veraverbeke *et al.* (2010a). Así, es complejo el determinar la razón de su relación con el DMC_{Canopy} , pero debido a los resultados, se puede estimar que la banda 7 del sensor OLI podría tener la posibilidad de estimar con mayor eficacia la sensibilidad de la absorción de la materia seca, donde se cree que ésta estaría por sobre la absorción del agua en dicho rango espectral, así como la banda insensible a la absorción sería la del infrarrojo cercano (banda 5), la misma que utiliza el NDII, por lo que dicha banda sería insensible a tanto la absorción de agua como a la de la materia seca en base a los resultados obtenidos.

Un estudio que pareció interesante de realizar fue el aplicar los resultados del modelo del FMC_s para determinar los valores del FMC a nivel hiperespectral se necesitan solo los dos índices que involucran el cálculo del primero i.e. NDII y NBR. El NDII se ha utilizado tanto a nivel hiperespectral Hunt Jr *et al.* (2013a) como a nivel satelital (Hardisky *et al.*, 1983), por lo que no conlleva una complejidad su cálculo. En tanto, el NBR solo ha sido utilizado a nivel satelital, por lo que se requirieron supuestos para establecer su valor a nivel hiperespectral. Así, el mejor resultado lo obtuvo la metodología que busca las longitudes de onda media de los valores que involucran el cálculo del NBR a partir de las bandas del sensor OLI. Ahora bien, los rangos obtenidos por esta aplicación del modelo varían considerablemente con los valores experimentales (FMC medido y FMC metodológico), donde éstos últimos fueron subestimados. El mínimo error hallado (RMSE) fue para el FMC estimado con el NBR mencionado con anterioridad con respecto al FMC metodológico, cuyo valor fue de 49,09 %. Así, se establece que no es factible el utilizar el modelo elaborado para estimar el FMC a nivel satelital para estimar la misma variable por medio de información hiperespectral. Cabe destacar que el modelo a nivel hiperespectral no puede ser llevado a nivel satelital, ya que considera el cálculo del WI, que considera valores de reflectancia puntuales con una distancia, en términos de longitud de onda, bastante estrecha, siendo imposible de estimar por parte del sensor OLI.

En tanto, es posible observar que tanto en el análisis espectral como satelital los índices que se utilizaron para estimar, indirectamente, el FMC difieren. Se puede desprender que en ambos métodos los resultados tienen una dependencia de la metodología empleada en cuanto a la recolección de muestras, el secado en el horno, y la especie estudiada. Se estima que la situación mejoraría bastante si, por ejemplo, se pudiese haber calculado en laboratorio el contenido de clorofila y carotenoides de las muestras con el fin de generar una simulación más “real” con PROSPECT (o bien un espectrómetro que abarque entre los 400–2.500 nm), como también utilizar, por ejemplo, instrumentos como un ceptómetro para determinar el LAI *in situ* con el fin de obtener mediciones reales del EWT y DMC a nivel del dosel, sin embargo estas opciones se alejan del objetivo del proyecto que, al final de cuentas, buscó establecer una metodología eficiente para determinar una variable sumamente relevante en la predicción de la ocurrencia y propagación del fuego: el FMC.

Trabajo a futuro

La finalidad de poder establecer una metodología más eficiente para determinar espacialmente el contenido de humedad en la biomasa (FMC) alude a un estudio de otra ciencia: la calorimetría. Ésta ciencia busca medir la cantidad de calor absorbido o liberado en una reacción química, mediante la utilización de instrumentos especializados llamados calorímetros, aparatos que permiten medir el calor consumido o liberado de una muestra al volver al equilibrio luego de una perturbación (Raudino *et al.*, 2011). El obtener el FMC a partir de información satelital da luces de que es factible establecer una metodología para obtener variables calorimétricas como el tiempo de ignición, el flujo de calor crítico y la energía liberada por la muestra (tasa de liberación de calor ó *Heat Release Rate*) a partir de información satelital, dado que, como ya se estudió, el FMC es una variable fundamental en el proceso de predecir la ocurrencia y el comportamiento del fuego (McAllister *et al.*, 2012).

Lo que se plantea como trabajo a futuro es el trabajar, en base a la misma metodología planteada en el presente proyecto, con información en relación a la calorimetría de los combustibles de la especie *pinus radiata*. De esta forma las muestras se someterán, a su vez, a otro estudio: la combustión en el calorímetro SCALA elaborado por alumnos y profesores de la UTFSM. El objetivo principal será el determinar una relación a partir de índices espectrales a nivel satelital que explique las variables calorimétricas mencionadas anteriormente para vegetación viva de la especie *pinus radiata*.

Conclusión

Los incendios en Chile han desatado una serie de escenarios devastadores. Los últimos dos más grandes han sido el del 2014 (en Valparaíso) y el de enero del 2017 (zona central y sur del país). Ambos en zonas WUI, arrasando con flora, fauna, viviendas y vidas humanas. De esta forma, se buscó generar una metodología para intentar aportar en la prevención del riesgo de estos desastres intentando cuantificar una variable sumamente relevante en la gestión del riesgo: el FMC. Sin embargo, la elaboración de ésta metodología lleva consigo una serie de supuestos y, también, se encontraron ciertos inconvenientes.

Comenzando por el análisis espectral de la vegetación, el hecho de contar con un espectrómetro que abarcara la porción del espectro comprendida entre los 650–1.100 nm radicó en tener que buscar alternativas para contar con un mayor rango espectral con el fin de lograr los objetivos planteados. PROSPECT fue la solución, y tres de los cinco parámetros que pide para su ejecución (simular el espectro entre los 400–2.500 nm) fueron estimados a partir de modelos estadísticos. Tal fue el caso de la clorofila a+b (C_{a+b}), carotenoides (C_{car}) y EWT. Para esto, se utilizó la base de datos LOPEX93. De esta forma, se utilizaron índices como el *Water Index* (WI) con el objeto de obtener un modelo de regresión con el EWT y el I.G.1 (índice de Gitelson 1) para obtener el modelo que estimase la clorofila a+b y carotenoides. El primer inconveniente nace aquí, dado que la base de datos cuenta solo con especies de tipo de hoja latifoliadas y no coníferas, como lo es el caso de la especie estudiada: *pinus radiata*. Hubiese sido interesante poder estimar, en laboratorio, el contenido de clorofila a+b como carotenoides para generar un modelo que se adecue a vegetación conífera.

Sin embargo, al utilizar PROSPECT para la simulación surgió un problema asociado a la determinación del parámetro de estructura interna (N), dado que las fórmulas existentes para determinar su valor resultaron con errores matemáticos por raíces negativas ($SLA < 0, 1 \text{ cm}^2/\text{mg}$) o bien resultados negativos. Lo anterior se debe, nuevamente, a que dichos modelos se han establecido para vegetación con tipo de hoja latifoliada y no conífera. Así, la metodología que se estableció para determinar el parámetro de estructura interna fue netamente visual. Se ingresaron todos los parámetros de PROSPECT y se fue variando el valor de N (entre 1 y 3) de modo que se ajustase lo mejor posible a la porción del espectro con la que se contaba: aquella obtenida por el espectrómetro.

Por otro lado, el EWT determinado por el modelo estadístico tuvo errores bastante exorbitantes en relación al obtenido en laboratorio. Si bien la regresión que se le realizó a la base de datos de LOPEX93, con el WI como variable independiente, arrojó una correlación de $R^2=0,95$, se puede dar cuenta de la diferencia de los resultados, dado que la media del error experimental entre el EWT obtenido del modelo y el EWT medido en laboratorio fue de 103 %. Dicho error se le atribuye, nuevamente, a las diferencias de las especies (latifoliadas versus conífera). En base a los errores obtenidos y la metodología empleada se puede destacar que se podría haber utilizado LIBERTY (modelo de transferencia radiativa para coníferas) en vez de PROSPECT, pero los parámetros de entrada del modelo son sumamente específicos y complejos de obtener. La razón de utilizar PROSPECT fue justamente porque (i) ha sido validado para una serie de especies y (ii) es menos complejo que otros modelos de transferencia radiativa debido a que minimiza el número de variables a invertir.

Por otra parte, como se estudió en la [Sección 2.2.3](#), obtener el espectro de vegetación con luz natural i.e. luz solar, lleva consigo una serie de errores. Dichos errores se hacen tangibles al estudiar las desviaciones estándar de las experiencias realizadas por muestra (ver [Sección 4.1.3](#)). En el caso de la primera experiencia, la desviación estándar de los datos fue bastante mayor que en las otras dos experiencias, en donde los errores más sustanciales se alcanzaron en la región del NIR (ver [Figura 4.8](#)). No obstante, la región del espectro visible también se vio afectada, lo que incidió en mayores errores para cálculos de índices que estiman el contenido de clorofila como lo son el Índice de Gitelson 1 y 2 (I.G.1 e I.G.2) y el msR-like (ver [Sección 5.3.2](#)).

De lo anterior se desprende que los resultados obtenidos del modelo para estimar el EWT_{Leaf} apuntan a que el mejor predictor fue el NMDI ($R^2=0,872$ y RMSE de $0,001899\text{ g/cm}^2$). El cual tuvo mejores resultados que el NDWI ($R^2=0,72$) y el WI ($R^2=0,869$), que han sido ampliamente utilizados en la literatura con el fin de estimar, indirectamente, el EWT. La gran diferencia entre estos tres índices es que el NMDI utiliza dos bandas de absorciones de agua en vez de una (como es el caso del NDWI y WI), por lo que se establece que bandas sensibles a nivel híperespectral para la vegetación bajo estudio se encuentran en torno a los 1.640 y 2.130 nm (bandas sensibles del NMDI). Ahora bien, el WI también tuvo excelentes resultados, por lo que se infiere que otra banda de absorción del agua se podría encontrar en torno a los 970 nm . En el caso del modelo para estimar el DMC_{Leaf} , el mejor predictor del modelo fue el WI a partir de un ajuste lineal ($R^2=0,933$ y RMSE de $0,000988\text{ g/cm}^2$). Este resultado es totalmente inesperado, y es interesante dar cuenta que los mejores índices para estimar, indirectamente, el DMC_{Leaf} fueron los que han sido creados para estimar el EWT_{Leaf} (NDWI, NMDI y SRWI). Se cree que la razón podría deberse a las diferencias entre plantas con hojas latifoliadas y coníferas, en donde si bien el patrón de comportamiento espectral es bastante similar, las curvas de absorción de la materia seca, al parecer, varían. Por otro lado, se cree que mientras que los coeficientes de absorción de la materia seca puedan ser mayores a los del agua en las regiones de los índices que tuvieron los mejores resultados, no es certero que éstos puedan estimar correctamente el DMC, debido a que existe, a menudo, mayor agua líquida que materia seca en las hojas, según lo establecieron *Yebra et al.* (2013).

Sin embargo, los resultados obtenidos de la estimación del EWT y DMC a nivel de hoja por índices espectrales (por espectrometría) entregaron resultados moderados (RMSE < 15 %). Los errores cuadráticos medios asociados al modelo para estimar el FMC i.e. el modelo generado a partir de la estimación del cociente de los modelos del EWT_{Leaf} y DMC_{Leaf} , se traduce en errores del modelo para el FMC medido en laboratorio y el obtenido a partir de la metodología del cociente del EWT y DMC a nivel de hoja. Para el primero, el RMSE fue de 14,20 % para un rango de valores del FMC medido en laboratorio entre 122,18 %–157,05 %. Para el segundo, el RMSE fue de 13,73 % para un rango de valores del FMC metodológico comprendido entre 123,3 %–154,16 %. En tanto, se puede establecer que el modelo (FMC_e) obtuvo una mayor dispersión de los datos en comparación con el FMC medido y el FMC metodológico, donde se ajustó de mejor forma con el último, que se ve reflejado en un menor RMSE.

Para el caso de la información satelital, cabe destacar, primeramente, que las imágenes provenientes del satélite Landsat 8 se utilizaron, principalmente, por tres razones. Primero, debido a que es de los pocos satélites que contemplan regiones en el infrarrojo de onda corta (SWIR). Segundo, ya que vienen previamente calibradas geográficamente, lo que facilita los tiempos de calibración y, por ende, la obtención de datos. Tercero, porque son de libre acceso.

El primer análisis de información satelital es asociado a la complejidad de la convergencia entre el día de muestreo y el paso del satélite. Fueron un total de cinco viajes a recolectar muestras y analizarlas en el laboratorio. Las primeras dos experiencias fueron fallidas, dado que se recolectó el mismo día que pasaba el satélite y la imágenes presentaron ruido atmosférico (nubosidad). Luego, se planteó modificar la metodología debido a los costos que se estaban incurriendo, por lo que se determinó que la recolección sería un día luego del paso del satélite con el fin de revisar la imagen previo a la recolección y trabajo de laboratorio. Claramente existe un error asociado a dicha metodología, pero los cambios temporales del FMC no son de un día a otro a menos que exista una gran diferencia entre ambos días, por ejemplo el día del paso del satélite estaba soleado y al otro día lloviendo, casos que no se dieron en el proyecto. De hecho, los resultados apuntan a que los cambios no fueron sustanciales, y parte del error que porta el modelo del FMC por información satelital se le atribuye a ésta metodología.

Para llevar los resultados del EWT y DMC a nivel del dosel es necesario amplificar ambas variables

por el LAI, el cual se obtuvo a partir de información satelital de un producto del sensor Modis de NASA (MCD15A2H), cuya validación presenta un RMSE de 0,69 según el autor del producto (Myneni y T.Park, 2015). Si se hubiese contado con instrumentos como un ceptómetro (que sirven para determinar el LAI indirectamente *in situ*) los resultados serían aún mas exactos. Es más, si se hubiese contado con los valores del LAI, se podría haber utilizado SAILH, modelo de transferencia radiativa a nivel del dosel, con el fin de simular el espectro reflectivo.

Por otra parte, los resultados obtenidos de la regresión para estimar los valores del EWT y DMC a nivel del dosel a partir de índices espectrales entregan información muy relevante. El índice que mayor relación tuvo con el EWT fue el NDII a partir de un ajuste lineal en donde la relación fue significativa e igual a $R^2=0,8371$, mientras que el RMSE fue de $0,00682 (g/cm^2)$. Para el caso del DMC a nivel del dosel, el índice que mejor se ajustó fue el NBR a partir de una relación lineal, donde la correlación fue de $R^2=0,8356$, mientras que el RMSE del modelo fue de $0,00477 (g/cm^2)$. La relación entre el NDII y EWT se había encontrado en la literatura, mas no la relación entre el NBR y el DMC. El NBR fue creado para ser utilizado a nivel satelital y que considera como banda sensible el MIR (*Middle Infrared*) y banda insensible el NIR (*Near Infrared*), con el objetivo de determinar la severidad de un incendio forestal. De esta forma, se puede corroborar lo que se ha establecido en la literatura, es decir, que la región del NIR es insensible a tanto la absorción de agua como de materia seca. También es posible concluir que es bastante probable que la banda 7 del sensor OLI (variable sensible inmersa en el cálculo del NBR) sea capaz de capturar la absorción de la materia seca para la vegetación bajo estudio. En la literatura se han definido una serie de regiones en donde las curvas de absorción de agua son mayores que la de la materia seca, pero al revés sólo se han encontrado pequeños tramos y para vegetación con hoja de tipo latifoliada y no conífera. Ahora bien, se requiere un mayor análisis para concluir con certeza lo anterior.

Respecto a los resultados anteriores del EWT y DMC a nivel del dosel por índices espectrales a nivel satelital, se concluye que el modelo empleado para cada caso, y por ende el modelo final para estimar el FMC, es exitoso mediante la metodología empleada (RMSE < 11 %), donde los errores cuadráticos medios (RMSE) para tanto la comparación del modelo del FMC_s con el FMC medido en laboratorio y aquel obtenido de la metodología del cociente entre el EWT y DMC a nivel de hoja, equivale a 10,80 % y 8,50 %, respectivamente, para los valores del FMC que contemplan un rango comprendido entre los 122,18 %–157,05 % para el caso del FMC medido en el laboratorio y 123,3 %–154,16 % para el caso del FMC obtenido de la metodología. En tanto, el modelo tendió a generar una mayor dispersión de los datos experimentales, pero se ajustó de mejor forma al FMC metodológico, que se condice con un menor RMSE.

En tanto, se intentó aplicar el modelo del FMC por medio de información satelital para estimar el FMC a nivel híperespectral (por espectrometría). No obstante, se concluye que no es factible de realizar, debido a que los errores hallados fueron bastante elevados, en donde el mejor resultado obtenido tuvo un RMSE de 49,09 % con respecto al FMC metodológico. No se pudo realizar al revés i.e. aplicar el modelo híperespectral para estimar el FMC a nivel satelital, debido a que el modelo para estimar el FMC a nivel híperespectral considera el cálculo del WI, un índice que involucra valores de reflectancias puntuales en torno a los 900 y 970 nm, por lo que es imposible obtener dichos valores físicos a partir de imágenes capturadas por el sensor OLI, que funciona en torno a bandas multispectrales.

En ambos estudios los modelos del FMC obtuvieron mejores resultados para el FMC determinado por la metodología del cociente entre el EWT y DMC a nivel de hoja. Se estima que la brecha de diferencia entre el FMC obtenido para la muestra total y el FMC por la metodología disminuiría si la cantidad de muestras “representativas” aumenta, en donde los resultados serían más acercados a los valores del FMC referentes a la muestra total (FMC_{Medido}).

Debe decirse que es bastante complejo el cumplir con los desafíos metodológicos propuestos por

Yebra *et al.* (2013), debido a que los resultados están intrínsecamente relacionados al tipo de sector en el que se recolectaron las muestras así como la especie de estudio. De esta forma, el presente modelo es posible de extenderse solo en sectores que cumplan una serie de supuestos en base a la metodología empleada. Entre otros, que la especie sea la misma, que el sector presente una homogeneidad de la especie en cuestión, que no se recolecten muestras en sectores donde existan extensas áreas sin árboles i.e. presencia de suelos llanos, y, por último, que el sector electo cumpla con similitudes topográficas y climáticas características de la V Región de Valparaíso, Chile.

Dentro de los errores en la estimación del FMC que se estudiaron, se destacan los errores asociados a los modelos de propagación del fuego de Rothermel (1972), los cuales son bastante sensibles al L-FMC (FMC vivo, el obtenido en el presente estudio). Por ejemplo, Jolly (2007) encontró que un 10 % de diferencia en el L-FMC podría producir hasta un 1.200 % de diferencia en la predicción de la propagación del fuego a partir de los modelos de propagación del fuego. Chuvieco *et al.* (2004a) determinan que variaciones del L-FMC de $\pm 20\%$ a un valor de L-FMC de 90 % resultaría pasar de un estado de bajo riesgo para, por ejemplo, pastizales, a alto (según la metodología empleada por ellos). Para el presente proyecto, los valores estudiados (todos) superan el 100 % de humedad, por lo que se alude al estudio de vegetación viva y el riesgo es, por ende, menor. Sin embargo, resultaría interesante analizar en conjunto con estos resultados la calorimetría asociada a la especie, con el fin de proponer un sistema más completo para la gestión del riesgo de incendios forestales.

Lo que se intentó demostrar en el proyecto es que el FMC puede ser estimado a partir de información tanto espectral como satelital, los resultados demuestran que es factible a partir de la metodología empleada. A partir de los resultados se determina que la metodología fue exitosa y que hay bastante holgura para mejorar. Así, se puede establecer que cumplen los objetivos propuestos.

Finalmente se concluye que si bien los resultados de los modelos se adecuaron aceptablemente a los resultados experimentales del FMC, dicha adecuación fue mayormente para la metodología empleada, que consistió en la obtención del peso fresco, peso seco y área de 10 agujas de pino representativas de la muestra. El fin del presente proyecto se amplía a un objetivo de mayor alcance. El hecho de poder determinar, en base a la metodología empleada, una relación para estimar, indirectamente, el FMC a nivel satelital, da luces de una posibilidad de poder determinar, indirectamente, variables asociadas a la calorimetría del combustible vivo i.e. variables como el tiempo de ignición, flujo crítico de calor, tasa de liberación de calor, entre otras, que son parte del trabajo a futuro.

Bibliografía

- 24-Horas (2017a). Joven agricultor muere mientras huía de un incendio forestal en galvarino. *Nacional*. Obtenida el 27 de Marzo de 2017, desde: <http://www.24horas.cl/nacional/joven-agricultor-muere-mientras-huia-de-un-incendio-forestal-en-galvarino-2269854>.
- 24-Horas (2017b). Quiénes son los fallecidos en los incendios a lo largo del país. *Nacional*. Obtenida el 27 de Marzo de 2017, desde: <http://www.24horas.cl/nacional/quienes-son-los-fallecidos-en-los-incendios-a-lo-largo-del-pais-2283098>.
- AGSENS (2015). Mediciones de reflectancia con espectrómetros Ocean Optics. *AGSENS – Soluciones de Equipamiento Tecnocientífico*. Manual proporcionado por personal de AGSENS (Sr. Juan Aguilera), distribuidores de la empresa Ocean Optics en Chile. El manual se obtuvo vía e-mail el día 3 de Noviembre de 2015.
- Aguado, I., Chuvieco, E., & Isabel, M. d. P. M. (2004). *Nuevas tecnologías para la estimación del riesgo de incendios forestales*, volume 4. Editorial CSIC-CSIC Press.
- Aguirre, M. A. (2013). *Introduction to space systems: design and synthesis*, volume 27. Springer Science & Business Media, Space Technology Library.
- Ajai, Kamat, D. S., Gs Chaturvedi, A. K. S., Sinha, & K, S. (1983). Spectral assessment of leaf area index, chlorophyll content and biomass of chickpea. *Photogrammetric Engineering and Rem. Sensing*, 49, 1721–1727.
- Akther, M. S. & Hassan, Q. K. (2011). Remote Sensing-Based Assessment of Fire Danger Conditions Over Boreal Forest. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, 4(4), 992–999.
- Al-Moustafa, T., Armitage, R. P., & Danson, F. M. (2012). Mapping fuel moisture content in upland vegetation using airborne hyperspectral imagery. *Remote Sensing of Environment*, 127, 74 – 83.
- Albini, F. (1976). Estimating wildfire behaviour and effects: USDA Forest Service, Intermountain Forest and Range Experiment Station. General Technical Report INT-30, 92.
- Ali, A. M., Darvishzadeh, R., Skidmore, A. K., van Duren, I., Heiden, U., & Heurich, M. (2016). Estimating leaf functional traits by inversion of prospect: Assessing leaf dry matter content and specific leaf area in mixed mountainous forest. *International Journal of Applied Earth Observation and Geoinformation*, 45, 66–76.
- Allen, W. A., Gausman, H. W., & Richardson, A. J. (1970). Mean effective optical constants of cotton leaves. *JOSA*, 60(4), 542–547.
- Allen, W. A., Gausman, H. W., Richardson, A. J., & Thomas, J. R. (1969). Interaction of isotropic light with a compact plant leaf. *J. Opt. Soc. Am.*, 59(10), 1376–1379.
- Anderson, H. E. (1982). Aids to determining fuel models for estimating fire behavior. *USDA Forest Service - Intermountain Forest and Range Experiment Station*, (General Technical Report INT-122. Ogden, Utah.), 28.
- Andrews, P. L. & Queen, L. P. (2001). Fire modeling and information system technology. *International Journal of Wildland Fire*, 10(4), 343–352.
- Asner, G. P. (1998). Biophysical and Biochemical Sources of Variability in Canopy Reflectance. *Remote Sensing of Environment*, 64(3), 234–253.

- Asner, G. P., Martin, R. E., Tupayachi, R., Emerson, R., Martinez, P., Sinca, F., Powell, G. V., Wright, S. J., & Lugo, A. E. (2011). Taxonomy and remote sensing of leaf mass per area (lma) in humid tropical forests. *Ecological Applications*, 21(1), 85–98.
- Asrar, G., Fuchs, M., Kanemasu, E. T., & Hatfield, J. L. (1984). Estimating Absorbed Photosynthetic Radiation and Leaf Area Index from Spectral Reflectance in Wheat. *Agronomy Journal*, 76(2), 300–306.
- Astrium (2015). Astrium Constellation Status. Obtenida el 14 de febrero de 2016, desde: <https://calval.cr.usgs.gov/wordpress/wp-content/uploads/Astrium-Constellation-Status.pdf>.
- Bakker, W. H., Feringa, W., Gieske, A. S. M., Grabmaier, K. A., Hecker, C. A., Horn, J. A., Huurneman, G. C., Janssen, L. L. F., Kerle, N., Van der Meer, F. D., Parodi, G. N., Pohl, C., Reeves, C. V., Van Ruitenbeek, F. J., Schetselaar, E. M., Tempfli, K., Weir, M. J. C., Westinga, E., Woldai, T., Tempfli, K., Kerle, N., Huurneman, G. C., & Janssen, L. L. F. (2009). *Principles of Remote Sensing - An introductory textbook*. The International Institute for Geo-Information Science and Earth Observation (ITC). Enschede, The Netherlands, 4 edición.
- Baret, F., Clevers, J. G. P. W., & Steven, M. D. (1995). The robustness of canopy gap fraction estimates from red and near-infrared reflectances: A comparison of approaches. *Remote Sensing of Environment*, 54(2), 141–151.
- Baret, F. & Fourty, T. (1997). Estimation of leaf water content and specific leaf weight from reflectance and transmittance measurements. *Agronomie*, 17(9-10), 455–464.
- Baret, F., Guyot, G., & Major, D. J. (1989). TSAVI: A vegetation index which minimizes soil brightness effects on LAI and APAR estimation. *Proc. IGARSS'89 and 12th Canadian Symposium on Remote Sensing, Vancouver, Canada*, (pp. 1355–1358).
- Baret, F., Hagolle, O., Geiger, B., Bicheron, P., Miras, B., Huc, M., Berthelot, B., Niño, F., Weiss, M., Samain, O., et al. (2007). Lai, fapar and fcover cyclopes global products derived from vegetation: Part 1: Principles of the algorithm. *Remote sensing of environment*, 110(3), 275–286.
- Baret, F., Weiss, M., Lacaze, R., Camacho, F., Makhmara, H., Pacholczyk, P., & Smets, B. (2013). Geov1: Lai and fapar essential climate variables and fcover global time series capitalizing over existing products. part1: Principles of development and production. *Remote Sensing of Environment*, 137, 299–309.
- Bartley, G. E. & Scolnik, P. A. (1995). Plant carotenoids: pigments for photoprotection, visual attraction, and human health. *The Plant Cell*, 7(7), 1027.
- Becerra, P. I. & Bustamante, R. O. (2008). The effect of herbivory on seedling survival of the invasive exotic species pinus radiata and eucalyptus globulus in a mediterranean ecosystem of central chile. *Forest Ecology and Management*, 256(9), 1573–1578.
- Beck, R. (2003). EO–1 User Guide. Version 2.3, for the Satellite Systems Branch, USGS Earth Resources Observation Systems Data Center (EDC). Obtenida el 10 de Enero de 2016, desde: <https://eo1.usgs.gov/documents/EO1userguidev2pt320030715UC.pdf>.
- Berjón, A. J. (2007). *Determinación de parámetros biofísicos de la cubierta vegetal mediante inversión de modelos de transferencia radiativa*. PhD thesis, Universidad de Valladolid – Departamento de Física Teórica, Atómica y Óptica.
- Bernstein, R. (1976). Digital image processing of earth observation sensor data. *IBM Journal of Research and Development*, 20(1), 40–57.

- Blackburn, G. A. (1998). Quantifying chlorophylls and carotenoids at leaf and canopy scales: An evaluation of some hyperspectral approaches. *Remote sensing of environment*, 66(3), 273–285.
- Blackburn, G. A. & Milton, E. J. (1995). Seasonal variations in the spectral reflectance of deciduous tree canopies. *International Journal of Remote Sensing*, 16(4), 709–720.
- Boegh, E., Soegaard, H., Broge, N., Hasager, C., Jensen, N., Schelde, K., & Thomsen, A. (2002). Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. *Remote Sensing of Environment*, 81(2), 179 – 193.
- Bowyer, P. & Danson, F. (2004). Sensitivity of spectral reflectance to variation in live fuel moisture content at leaf and canopy level. *Remote Sensing of Environment*, 92(3), 297 – 308. Forest Fire Prevention and Assessment.
- Bradshaw, L. S., Deeming, J. E., Burgan, R. E., & Cohen, J. D. (1983). The 1978 National Fire-Danger Rating System: Technical Documentation.
- Bréda, N. J. (2003). Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. *Journal of experimental botany*, 54(392), 2403–2417.
- Broge, N. H. & Leblanc, E. (2000). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*, 76(2), 156–172.
- Brown, L., Chen, J. M., Leblanc, S. G., & Cihlar, J. (2000). A Shortwave Infrared Modification to the Simple Ratio for LAI Retrieval in Boreal Forests: An Image and Model Analysis. *Remote Sensing of Environment*, 71(1), 16–25.
- Burgan, R. E. (1987). A comparison of procedures to estimate fine dead fuel moisture for fire behaviour predictions. *South African Forestry Journal*, 142(1), 34–40.
- Burgan, R. E. (1988). Revisions to the 1978 National Fire-Danger Rating System.
- Burgan, R. E. & Hartford, R. A. (1993). Monitoring Vegetation Greenness With Satellite Data.
- Burgan, R. E., Hartford, R. A., & Eidenshink, J. C. (1996). Using NDVI Departure From Average Greenness and its Relation to Fire Business.
- Burgan, R. E., Klaver, R. W., & Klaver, J. M. (1998). Fuel Models and Fire Potential From Satellite and Surface Observations. *International Journal of Wildland Fire*, 8(3), 159–170.
- Burgan, R. E. & Rothermel, R. C. (1984). *BEHAVE: Fire Behavior Prediction and Fuel Modeling System – FUEL Subsystem*. PMS 439-1; NFES 0275, A publication of the National Wildfire Coordinating Group. United States Department of Agriculture (USDA), United States Department of the Interior and National Association of State Foresters.
- Butler, B., Cohen, J., Latham, D., Schuette, R., Sopko, P., Shannon, K., Jimenez, D., & Bradshaw, L. (2004). Measurements of radiant emissive power and temperatures in crown fires. *Canadian Journal of Forest Research*, 34(8), 1577–1587.
- BWTEK (2016). Spectrometer Knowledge – How Does a Spectrometer Work? Obtenida el 3 de Julio de 2016, desde: <http://bwtek.com/spectrometer-introduction/>.
- Campbell, J. B. & Wynne, R. H. (2011). *Introduction to Remote Sensing*. New York, United States: The Guilford Press, 5th edición.
- Caramelle, P. & Clément, A. (1978). *Inflammabilité et combustibilité de la végétation méditerranéenne*. Service des Forêts.

- Carter, G. A. (1991). Primary and Secondary Effects of Water Content on the Spectral Reflectance of Leaves. *American Journal of Botany*, 78(7), 916–924.
- Castillo, M., Guillermo, J., & Quintanilla, V. (2011). Vulnerabilidad y daño potencial ocasionado por incendios en áreas de interfaz urbano-forestal, provincia de Valparaíso. Chile central. *Territorium*, 18, 247–254.
- Castillo, M., Quintanilla, V., & Julio, G. (2009). Análisis del riesgo y vulnerabilidad contra incendios forestales en áreas de interfaz, provincia de Valparaíso. *Territorium: Revista Portuguesa de riscos, prevenção e segurança*, (16).
- Castro, M., Parra, J., Morales, L., & Salas, C. (2014). Establishment of empirical relations between fuel moisture content and the normalised difference vegetation index. *Journal of soil science and plant nutrition*, 14(3), 670–675.
- CCRM (2014). Fundamentals of Remote Sensing. Canada Centre for Remote Sensing - Natural Resources Canada. Obtenido el 19 de Junio de 2015, desde: <http://www.nrcan.gc.ca/earth-sciences/geomatics/satellite-imagery-air-photos/satellite-imagery-products/educational-resources/9309>.
- Ceccato, P., Flasse, S., & Grégoire, J.-M. (2002a). Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. *Remote Sensing of Environment*, 82(2-3), 198–207.
- Ceccato, P., Gobron, N., Flasse, S., Pinty, B., & Tarantola, S. (2002b). Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1: Theoretical approach. *Remote Sensing of Environment*, 82(2-3), 188–197.
- Ceccato, P., Leblon, B., Chuvieco, E., Flasse, S., & Carlson, J. D. (2003). Estimation of live fuel moisture content. In E. Chuvieco (Ed.), *Wildland fire danger estimation and mapping. The role of remote sensing data* (pp. 63–90). Singapore: World Scientific Publishing.
- Ceccato, P., Tarantola, S., Flasse, S., Jacquemoud, S., & Grégoire, J.-M. (2001). Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, 77(1), 22–33.
- Chappelle, E. W., Kim, M. S., & McMurtrey, J. E. (1992). Ratio analysis of reflectance spectra (rars): an algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b, and carotenoids in soybean leaves. *Remote Sensing of Environment*, 39(3), 239–247.
- Chas-Amil, M., Touza, J., & García-Martínez, E. (2013). Forest fires in the wildland–urban interface: a spatial analysis of forest fragmentation and human impacts. *Applied Geography*, 43, 127–137.
- Chavez, P. (1975). Atmospheric, solar, and mtf corrections for erts digital imagery. *Proceedings of the American Society of Photogrammetry*, 68.
- Chavez, P. S. (1988). An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote sensing of environment*, 24(3), 459–479.
- Chavez, P. S. (1996). Image-based atmospheric corrections-revisited and improved. *Photogrammetric engineering and remote sensing*, 62(9), 1025–1035.
- Chen, J. M. (1996). Evaluation of vegetation indices and a modified simple ratio for boreal applications. *Canadian Journal of Remote Sensing*, 22(3), 229–242.
- Chen, J. M. & Cihlar, J. (1996). Retrieving leaf area index of boreal conifer forests using landsat tm images. *Remote sensing of Environment*, 55(2), 153–162.

- Chowdhury, E. H. & Hassan, Q. K. (2015). Operational perspective of remote sensing-based forest fire danger forecasting systems. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104(0), 224–236.
- Chrosciewicz, Z. (1986). Foliar moisture content variations in four coniferous tree species of central alberta. *Canadian Journal of Forest Research*, 16(1), 157–162.
- Chuvieco, E. (1990). *Fundamentos de Teledetección Espacial*. Madrid, España: Ediciones Rialp, S. A., segunda edición.
- Chuvieco, E. (2010). *Teledetección Ambiental: La observación de la Tierra desde el espacio*. Barcelona, España., ariel ciencia edición. 3º edición en esta presentación, actualizada: Octubre de 2010.
- Chuvieco, E., Aguado, I., Cocero, D., & Riaño, D. (2003a). Design of an empirical index to estimate fuel moisture content from NOAA-AVHRR images in forest fire danger studies. *International Journal of Remote Sensing*, 24(8), 1621–1637.
- Chuvieco, E., Aguado, I., & Dimitrakopoulos, A. P. (2004a). Conversion of fuel moisture content values to ignition potential for integrated fire danger assessment. *Canadian Journal of Forest Research*, 34(11), 2284–2293.
- Chuvieco, E., Cocero, D., Riaño, D., Martín, P., Martínez-Vega, J., de la Riva, J., & Pérez, F. (2004b). Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. *Remote Sensing of Environment*, 92(3), 322–331.
- Chuvieco, E., González, I., Verdú, F., Aguado, I., & Yebra, M. (2009). Prediction of fire occurrence from live fuel moisture content measurements in a mediterranean ecosystem. *International Journal of Wildland Fire*, 18(4), 430–441.
- Chuvieco, E., Martín Isabel, M. P., Martínez, J., & Salas, F. J. (1998). Geografía e incendios forestales. *Serie Geográfica*, 7, 11–17.
- Chuvieco, E., Riaño, D., Aguado, I., & Cocero, D. (2002). Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: applications in fire danger assessment. *International Journal of Remote Sensing*, 23(11), 2145–2162.
- Chuvieco, E., Riaño, D., Van Wagtenonk, J. W., & Morsdorf, F. (2003b). Fuel Loads and Fuel Type Mapping. In E. Chuvieco (Ed.), *Wildland Fire Danger Estimation and Mapping: The Role of Remote Sensing Data*, volume 4. USA/UK: World Scientific Publishing Co. Ptc. Ltd.
- CIREN (2016). Página web del instituto. *Centro de Información de Recursos Naturales*. Datos obtenidos el 27 de Junio de 2016, desde: <http://www.ciren.cl/>.
- Close, D. C. & Beadle, C. L. (2003). The ecophysiology of foliar anthocyanin. *The Botanical Review*, 69(2), 149–161.
- Cocero, D., Riaño, D., Meza, E., Chuvieco, E., & CSIC, E. (2004). In . E. Chuvieco, *Nuevas tecnologías para la estimación del riesgo de incendios forestales*, volume 4 chapter III, (pp. 33–62). España, csic edición.
- Cohen, J. D. & Deeming, J. E. (1985). The National Fire Danger Rating System: basic equations.
- CONAF (1987-2004). Estadísticas de Causas según Daño de Incendios Forestales entre los años 1987 - 2014. Obtenido el 13 de Octubre de 2015, desde: <http://www.conaf.cl/incendios-forestales/incendios-forestales-en-chile/estadisticas-historicas/>.

- CONAF (2011). Manual con Medidas para la Prevención de Incendios Forestales - Región Valparaíso. Obtenido el 19 de Junio, 2015 de http://www.conaf.cl/wp-content/files_mf/1361284710manual_Valpara%C3%ADsobaja.pdf.
- CONAF (2015a). Detección de incendios forestales: Sistemas de detección. Obtenida el 13 de Junio de 2015 desde: <http://www.conaf.cl/incendios-forestales/combate-de-incendios-forestales/deteccion-de-incendios-forestales/>.
- CONAF (2015b). Número de incendios forestales y superficie afectada a la fecha. Los valores se actualizan de manera automática, cada 15 minutos. Obtenida de: <http://www.conaf.cl/incendios-forestales/incendios-forestales-en-chile/estadistica-de-ocurrencia-diaria/>.
- CONAF (2015c). Pronóstico del grado de peligro: definición y cálculo.
- CONAF (2016a). Estadísticas – Causas según Ocurrencia de Incendios Forestales 1987 – 2015. *Comisión Nacional Forestal – Estadísticas Históricas de Incendios Forestales*. Obtenida el 17 de Julio de 2016, desde: <http://www.conaf.cl/incendios-forestales/incendios-forestales-en-chile/estadisticas-historicas/>.
- CONAF (2016b). Estadísticas – Ocurrencia (Número) y Daño (Superficie Afectada) por Incendios Forestales, ámbito CONAF 1985–2015. *Comisión Nacional Forestal – Estadísticas Históricas de Incendios Forestales*. Obtenida el 24 de Junio de 2016, desde: <http://www.conaf.cl/incendios-forestales/incendios-forestales-en-chile/estadisticas-historicas/>.
- CONAF (2016c). Incendios Forestales en Chile. *Comisión Nacional Forestal*. Obtenida el 27 de Junio de 2016, desde: <http://www.conaf.cl/incendios-forestales/incendios-forestales-en-chile/>.
- CONAF (2017). *Análisis de la Afectación y Severidad de los Incendios Forestales ocurridos en enero y febrero de 2017 sobre los usos de suelo y los ecosistemas naturales presentes entre las regiones de Coquimbo y La Araucanía de Chile. Informe técnico*. 56 p. Santiago, Chile. Technical report, Comisión Nacional Forestal.
- Contreras, C. (2016). Empleo de índices espectrales en la estimación de los principales parámetros y variables que determinan el comportamiento ante incendios de agujas de Pino Radiata. Memoria para optar al título de Ingeniero Civil Industrial. Universidad Técnica Federico Santa María – Departamento de Industrias.
- Cooperativa (2017). Quirihue: Adulto mayor murió por paro cardíaco producto de incendios forestales. *País*. Obtenida el 27 de marzo de 2017, desde: <https://www.cooperativa.cl/noticias/pais/desastres-naturales/incendios-forestales/adulto-mayor-murio-por-un-paro-cardiaco-producto-de-los-incendios/2017-01-29/182612.html>.
- Crouch, S. & Skoog, D. (2007). *Principles of instrumental analysis*. Australia: Thomson Brooks/Cole.
- CSI-NASA (2015). Energy: The driver of climate - electromagnetic radiation. (Climate Science Investigations (CSI) - NASA.). Obtenida el 18 de Octubre de 2015, desde: <http://www.ces.fau.edu/nasa/module-2/radiation-sun.php>.
- Danson, F. M. & Bowyer, P. (2004). Estimating live fuel moisture content from remotely sensed reflectance. *Remote Sensing of Environment*, 92(3), 309–321.
- Danson, F. M., Steven, M. D., Malthus, T. J., & Clark, J. A. (1992). High-spectral resolution data for determining leaf water content. *International Journal of Remote Sensing*, 13(3), 461–470.
- Datt, B. (1998). Remote sensing of chlorophyll a, chlorophyll b, chlorophyll a+b, and total carotenoid content in eucalyptus leaves. *Remote Sensing of Environment*, 66(2), 111 – 121.

- Datt, B. (1999a). Remote sensing of water content in eucalyptus leaves. *Australian Journal of Botany*, 47(6), 909–923.
- Datt, B. (1999b). Visible/near infrared reflectance and chlorophyll content in eucalyptus leaves. *International Journal of Remote Sensing*, 20(14), 2741–2759.
- Daughtry, C. S. T., Hunt, E. R., Doraiswamy, P. C., & McMurtrey, J. E. (2005). Remote sensing the spatial distribution of crop residues. *Agronomy Journal*, 97(3), 864–871.
- Dawson, T. P., Curran, P. J., North, P. R. J., & Plummer, S. E. (1999). The Propagation of Foliar Biochemical Absorption Features in Forest Canopy Reflectance: A Theoretical Analysis. *Remote Sensing of Environment*, 67(2), 147–159.
- Dawson, T. P., Curran, P. J., & Plummer, S. E. (1998). Liberty—modeling the effects of leaf biochemical concentration on reflectance spectra. *Remote Sensing of Environment*, 65(1), 50 – 60.
- Dennison, P. E., Moritz, M. A., & Taylor, R. S. (2008). Evaluating predictive models of critical live fuel moisture in the santa monica mountains, california. *International Journal of Wildland Fire*, 17(1), 18–27.
- Dennison, P. E., Roberts, D. A., Peterson, S. H., & Rechel, J. (2005). Use of normalized difference water index for monitoring live fuel moisture. *International Journal of Remote Sensing*, 26(5), 1035–1042.
- Desbois, N., Deshayes, M., & Beaudoin, A. (1997a). Protocol for fuel moisture content measurements. In E. Chuvieco (Ed.), *A review of remote sensing methods for the study of large wildland fires* (pp. 61–72). Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá.
- Desbois, N., Pereira, J. M. C., Beaudoin, A., Chuvieco, E., & Vidal, A. (1997b). Short term fire risk mapping using remote sensing. In E. Chuvieco (Ed.), *A review of remote sensing methods for the study of large wildland fires* (pp. 29–60). Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá.
- Dettwiler, M. (2015). RapidEye Data Sheet. Obtenido el 14 de febrero de 2016, desde: http://www.blackbridge.com/rapideye/upload/RE_Product_Specifications_ENG.pdf.
- DigitalGlobe (2015a). GeoEye – 1 Data Sheet. Obtenida el 14 de febrero de 2016, desde: http://global.digitalglobe.com/sites/default/files/DG_GeoEye1.pdf.
- DigitalGlobe (2015b). Ikonos Data Sheet. Obtenida el 14 de febrero de 2016, desde: http://global.digitalglobe.com/sites/default/files/DG_IKONOS_DS.pdf.
- DigitalGlobe (2015c). QuickBird Data Sheet. Obtenido el 14 de febrero de 2016, desde: <http://global.digitalglobe.com/sites/default/files/QuickBird-DS-QB-Prod.pdf>.
- DigitalGlobe (2015d). WorldView-2 Data Sheet. Obtenida el 14 de febrero de 2016, desde: http://global.digitalglobe.com/sites/default/files/DG_WorldView2_DS_PROD.pdf.
- DigitalGlobe (2015e). WorldView-3 Data Sheet. Obtenida el 14 de febrero de 2016, desde: http://global.digitalglobe.com/sites/default/files/DG_WorldView3_DS_forWeb_0.pdf.
- Dimitrakopoulos, A. P. & Papaioannou, K. K. (2001). Flammability Assessment of Mediterranean Forest Fuels. *Fire Technology*, 37(2), 143–152.
- Diner, D. J., Asner, G. P., Davies, R., Knyazikhin, Y., Muller, J.-P., Nolin, A. W., Pinty, B., Schaaf, C. B., & Stroeve, J. (1999). New Directions in Earth Observing: Scientific Applications of Multiangle Remote Sensing. *Bulletin of the American Meteorological Society*, 80(No. 11, November 1999).

- Downing, H. G., Carter, G. A., Holladay, K. W., & Cibula, W. G. (1993). The radiative-equivalent water thickness of leaves. *Remote Sensing of Environment*, 46(1), 103 – 107.
- Drysdale, D. (2011). *An introduction to fire dynamics*. John Wiley & Sons.
- EcoAgricultura (2015). Plantas medicinales: Laurel (*Laurus nobilis* L.). *El Medio Natural, La Agricultura y los Alimentos*. Obtenida el 8 de Diciembre de 2015, <http://www.ecoagricultura.net/plantas-medicinales-laurel-laurus-nobilis-l/>.
- Elvidge, C. D. & Chen, Z. (1995). Comparison of broad-band and narrow-band red and near-infrared vegetation indices. *Remote Sensing of Environment*, 54(1), 38–48.
- Emol (2017). Bombera murió a causa de un aneurisma tras combatir incendios forestales en el biobío. *Nacional*. Obtenida el 27 de Marzo de 2017, desde: <http://www.emol.com/noticias/Nacional/2017/01/30/842533/Bombera-que-combatio-incendios-durante-dos-dias-murio-a-causa-de-un-aneurisma.html>.
- Estes, J. E. & Simonett, D. S. (1975). Fundamentals of image interpretation. In R. G. Reeves (Ed.), *Manual of Remote Sensing*. Falls Church: American Society of Photogrammetry. pp. 869-1076.
- EUMETSAT (2015). Meteosat: Monitoring weather and climate from space. Obtenida el 21 de Junio de 2015, desde: <http://www.eumetsat.int/website/home/Satellites/CurrentSatellites/Meteosat/index.html>.
- Fensholt, R. & Sandholt, I. (2003). Derivation of a shortwave infrared water stress index from MODIS near- and shortwave infrared data in a semiarid environment. *Remote Sensing of Environment*, 87(1), 111–121.
- Féret, J.-B., François, C., Gitelson, A., Asner, G. P., Barry, K. M., Panigada, C., Richardson, A. D., & Jacquemoud, S. (2011). Optimizing spectral indices and chemometric analysis of leaf chemical properties using radiative transfer modeling. *Remote Sensing of Environment*, 115(10), 2742–2750.
- Feret, J.-B., François, C., Asner, G. P., Gitelson, A. A., Martin, R. E., Bidel, L. P., Ustin, S. L., le Maire, G., & Jacquemoud, S. (2008). Prospect-4 and 5: Advances in the leaf optical properties model separating photosynthetic pigments. *Remote Sensing of Environment*, 112(6), 3030 – 3043.
- Fernandes, R., Plummer, S., Nightingale, J., Baret, F., Camacho, F., Fang, H., Garrigues, S., Gobron, N., Lang, M., Lacaze, R., LeBlanc, S., Meroni, M., Martinez, B., Nilson, T., Pinty, B., Pisek, J., Sonnentag, O., Verger, A., Welles, J., Weiss, M., & Widlowski, J. L. (2014). *Global Leaf Area Index Product Validation Good Practices. Version 2.0.1*. In Schaepman-Strub, G., Román, M., & Nickeson, J (Eds.), *Best Practice for Satellite-Derived Land Product Validation* (p. 76): Land Product Validation Subgroup (WGCV/CEOS).
- Fernández, F. M. (2003). FASat-Alfa, el primer satélite chileno: Descripción de la misión. Obtenido el 20 de Julio de 2015, desde: <http://www.fasat.aviacion.cl/mision.htm>.
- Finney, M. A. (1998). FARSITE: FFire area simulator – Model development and evaluation. *USDA Forest Service, Rocky Mountain Research Station, Research Paper RMRS-RP-4* (Fort Collins, CO. 51pp).
- Finney, M. A., McHugh, C. W., Grenfell, I., Riley, K. L., & Viegas, D. X. (2010). Continental-scale simulation of burn probabilities, flame lengths, and fire size distribution for the United States. In *Proceedings of the VI International Conference on Forest Fire Research, University of Coimbra, Coimbra, Portugal* (pp. 15–18).
- Font, R., Conesa, J., Moltó, J., & Munoz, M. (2009). Kinetics of pyrolysis and combustion of pine needles and cones. *Journal of Analytical and Applied Pyrolysis*, 85(1), 276–286.

- Fourty, T. & Baret, F. (1997). Vegetation water and dry matter contents estimated from top-of-the-atmosphere reflectance data: A simulation study. *Remote Sensing of Environment*, 61(1), 34 – 45.
- FOXNEWS (2014). Forest fire kills 16, destroys 500 homes in Chile city. Obtenido el 11 de Octubre de 2015, desde: <http://www.foxnews.com/world/2014/04/13/forest-fire-destroys-at-least-150-homes-sparks-evacuations-in-chilean-city/>.
- Ganguly, S., Nemani, R. R., Zhang, G., Hashimoto, H., Milesi, C., Michaelis, A., Wang, W., Votava, P., Samanta, A., Melton, F., *et al.* (2012). Generating global leaf area index from landsat: Algorithm formulation and demonstration. *Remote Sensing of Environment*, 122, 185–202.
- Gao, B.-C. (1996). NDWI: A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266.
- Gao, B.-C. & Goetz, A. F. H. (1995). Retrieval of equivalent water thickness and information related to biochemical components of vegetation canopies from AVIRIS data. *Remote Sensing of Environment*, 52(3), 155–162.
- Gao, F., Anderson, M. C., Kustas, W. P., & Wang, Y. (2012). Simple method for retrieving leaf area index from landsat using modis leaf area index products as reference. *Journal of Applied Remote Sensing*, 6(1), 063554–1.
- Gao, X., Huete, A. R., Ni, W., & Miura, T. (2000). Optical–Biophysical Relationships of Vegetation Spectra without Background Contamination. *Remote Sensing of Environment*, 74(3), 609–620.
- García, M., Chuvieco, E., Nieto, H., & Aguado, I. (2008). Combining {AVHRR} and meteorological data for estimating live fuel moisture content. *Remote Sensing of Environment*, 112(9), 3618 – 3627.
- Garmin (2007). Manual del usuario Serie eTrex HCx. Obtenida el 1 de Octubre de 2016, desde: <http://www.jancat.net/pda/Manual%20Garmin%20etrex%20vista%20hcx.pdf>.
- Garnier, E., Laurent, G., Bellmann, A., Debain, S., Berthelie, P., Ducout, B., Roumet, C., & Navas, M.-L. (2001). Consistency of species ranking based on functional leaf traits. *New Phytologist*, 152(1), 69–83.
- Garnier, E. & Navas, M.-L. (2012). A trait-based approach to comparative functional plant ecology: concepts, methods and applications for agroecology. a review. *Agronomy for Sustainable Development*, 32(2), 365–399.
- Gates, D. M. (1991). Water relations of forest trees. *IEEE Transactions on Geoscience and Remote Sensing*, 29(6), 836–842.
- Gates, D. M., Keegan, H. J., Schleter, J. C., & Weidner, V. R. (1965). Spectral properties of plants. *Applied Optics*, 4, pp. 11–20.
- Gilabert, M., Conese, C., & Maselli, F. (1994). An atmospheric correction method for the automatic retrieval of surface reflectances from tm images. *International Journal of Remote Sensing*, 15(10), 2065–2086.
- Gilabert, M. A., González-Piqueras, J., & García-Haro, J. (1997). Acerca de los índices de vegetación. *Revista de Teledetección*, N°8, pp. 10.
- Gitelson, A. & Merzlyak, M. N. (1994). Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. *Journal of Photochemistry and Photobiology B: Biology*, 22(3), 247–252.

- Gitelson, A. A., Buschmann, C., & Lichtenthaler, H. K. (1998). Leaf chlorophyll fluorescence corrected for re-absorption by means of absorption and reflectance measurements. *Journal of Plant Physiology*, 152(2–3), 283 – 296.
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271 – 282.
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289–298.
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76–87.
- Gitelson, A. A. & Merzlyak, M. N. (1998). Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in Space Research*, 22(5), 689 – 692. Synergistic Use of Multisensor Data for Land Processes.
- G.O.E (2015a). Aplicaciones del SSOT y su aporte al desarrollo del país. Obtenida el 12 de Junio de 2015, desde: <http://www.ssot.cl/aplicaciones.php>.
- G.O.E (2015b). Modelo de explotación y políticas de acceso a las imágenes de FASat-Charlie. Obtenido el 12 de Junio de 2015, desde: <http://www.ssot.cl/modelo.php>.
- Goel, N. S. (1988). Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. *Remote Sensing Reviews*, 4(1), 1–212.
- Goetz, A. F. H., Vane, G., Solomon, J. E., & Rock, B. N. (1985). Imaging Spectrometry for Earth Remote Sensing. *Science*, 228(4704), 1147–1153.
- Gond, V., de Pury, D. G. G., Veroustraete, F., & Ceulemans, R. (1999). Seasonal variations in leaf area index, leaf chlorophyll, and water content; scaling-up to estimate fAPAR and carbon balance in a multilayer, multispecies temperate forest. *Tree Physiology*, 19(10), 673–679.
- Gonsamo, A. (2010). Leaf area index retrieval using gap fractions obtained from high resolution satellite data: Comparisons of approaches, scales and atmospheric effects. *International Journal of Applied Earth Observation and Geoinformation*, 12(4), 233–248.
- Gonsamo, A. & Chen, J. M. (2014). Continuous observation of leaf area index at Fluxnet-Canada sites. *Agricultural and Forest Meteorology*, 189–190(0), 168–174.
- Gould, K., Davies, K. M., & Winefield, C. (2008). *Anthocyanins: biosynthesis, functions, and applications*. Springer Science & Business Media.
- Govaerts, Y. M., Jacquemoud, S., Verstraete, M. M., & Ustin, S. L. (1996). Three-dimensional radiation transfer modeling in a dicotyledon leaf. *Applied Optics*, 35(33), 6585–6598.
- Goward, S. N. & Huemmrich, K. F. (1992). Vegetation canopy PAR absorptance and the normalized difference vegetation index: An assessment using the SAIL model. *Remote Sensing of Environment*, 39(2), 119–140.
- Gower, S. T., Kucharik, C. J., & Norman, J. M. (1999). Direct and indirect estimation of leaf area index, f apar, and net primary production of terrestrial ecosystems. *Remote sensing of environment*, 70(1), 29–51.
- Green, E. P., Mumby, P. J., Edwards, A. J., & Clark, C. D. (2005). Remote sensing handbook for tropical coastal management.

- Gulácsi, A. & Kovács, F. (2015). Drought monitoring with spectral indices calculated from modis satellite images in hungary. *Journal of Environmental Geography*, 8(3-4), 11–20.
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., & Strachan, I. B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3), 337–352.
- Hantson, S., Padilla, M., Corti, D., & Chuvieco, E. (2013). Strengths and weaknesses of MODIS hotspots to characterize global fire occurrence. *Remote Sensing of Environment*, 131(0), 152–159.
- Hardisky, M. A., Klemas, V., & Smart, R. M. (1983). The influence of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Rem. Sensing*, 49, 77–83.
- Harriscaprock (2014). High Throughput Satellite Communications Systems: MEO vs. LEO vs. GEO. Obtenida el 13 de febrero de 2016, desde: <http://www.harriscaprock.com/blog/high-throughput-satellite-communications-systems-meo-vs-leo-vs-geo/>.
- Horler, D., Dockray, M., & Barber, J. (1983). The red edge of plant leaf reflectance. *International Journal of Remote Sensing*, 4(2), 273–288.
- Hosgood, B., Jacquemoud, S., Andreoli, G., Verdebout, J., Pedrini, G., & Schmuck, G. (1994). *Leaf Optical Properties Experiment 93 (LOPEX93)*. Report EUR 16095 EN, p. 21, European Commission, Joint Research Centre, Institute for Remote Sensing Applications.
- Houborg, R., McCabe, M., Cescatti, A., Gao, F., Schull, M., & Gitelson, A. (2015). Joint leaf chlorophyll content and leaf area index retrieval from landsat data using a regularized model inversion system (regflec). *Remote Sensing of Environment*, 159, 203–221.
- Huang, N., He, J.-S., & Niu, Z. (2013). Estimating the spatial pattern of soil respiration in Tibetan alpine grasslands using Landsat TM images and MODIS data. *Ecological Indicators*, 26(0), 117–125.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309.
- Huete, A. R., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195–213.
- Hunt Jr, E. R., Cheng, T., Riaño, D., Ustin, S. L., Wang, L., Hao, X., Qu, J. J., & Daughtry, C. S. (2013). Determining leaf dry matter content using the normalized dry matter index and its possible application for estimating fuel moisture content. In *Meeting Abstract* (pp. 29–30): J.
- Hunt Jr, E. R., Daughtry, C. S. T., Qu, J. J., Wang, L., & Hao, X. (2011). Comparison of hyperspectral retrievals with vegetation water indices for leaf and canopy water content.
- Hunt Jr, E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry, C. S. T., Perry, E. M., & Akhmedov, B. (2013a). A visible band index for remote sensing leaf chlorophyll content at the canopy scale. *International Journal of Applied Earth Observation and Geoinformation*, 21(0), 103–112.
- Hunt Jr, E. R. & Rock, B. N. (1989). Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. *Remote Sensing of Environment*, 30(1), 43–54.
- Hunt Jr, E. R., Rock, B. N., & Nobel, P. S. (1987). Measurement of leaf relative water content by infrared reflectance. *Remote Sensing of Environment*, 22(3), 429–435.

- Hunt Jr, E. R., Ustin, S. L., & Riaño, D. (2013b). Remote sensing of leaf, canopy, and vegetation water contents for satellite environmental data records. In: *Satellite-based Applications on Climate Change* (Chapter 20), Qu, J., Powell, A. & Sivakumar, M. V. K. (Eds.). 1st Edition, Springer Netherlands.
- ICONA (1968-1995). Los incendios forestales en España. Publicación Anual. Madrid, España. Instituto Nacional para la Conservación de la Naturaleza. Ministerio de Agricultura, Pesca y Alimentación.
- Illera, P., Fernandez, A., & Delgado, J. A. (1996). Temporal evolution of the NDVI as an indicator of forest fire danger. *International Journal of Remote Sensing*, 17(6), 1093–1105.
- INE (2005). *CHILE: Ciudades, Pueblos, Aldeas y Caseríos*. Santiago, Chile: Instituto Nacional de Estadísticas. Obtenido el 13 de Julio de 2015, desde: http://www.ine.cl/canales/usuarios/cedoc_online/censos/pdf/censo_2002_publicado_junio_2005.pdf.
- INE (2010). Estadísticas demográficas. *Instituto Nacional de Estadísticas – Compendio Estadístico*. Obtenido el 27 de Junio de 2016, desde: http://www.ine.cl/canales/menu/publicaciones/compendio_estadistico/pdf/2010/1.2estdemograficas.pdf.
- INE (2016). País y regiones total: actualización población 2002–2012 y proyecciones 2013–2020. *Instituto Nacional de Estadísticas – Demografías y Vitales*. Obtenida el 27 de Junio de 2016, desde: http://www.ine.cl/canales/chile_estadistico/familias/demograficas_vitales.php.
- Jackson, T. J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., Doriaswamy, P., & Hunt, E. R. (2004). Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sensing of Environment*, 92(4), 475–482.
- Jacquemoud, S. & Baret, F. (1990). PROSPECT: A model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(2), 75–91.
- Jacquemoud, S., Baret, F., Andrieu, B., Danson, F. M., & Jaggard, K. (1995). Extraction of vegetation biophysical parameters by inversion of the PROSPECT + SAIL models on sugar beet canopy reflectance data. Application to TM and AVIRIS sensors. *Remote Sensing of Environment*, 52(3), 163–172.
- Jacquemoud, S. & Ustin, L. (2008). Modeling leaf optical properties. *Photobiological Sciences Online*. Obtenido desde: http://photobiology.info/Jacq_Ustin.html (consultado el 28 de Junio de 2016).
- Jacquemoud, S., Ustin, S., Verdebout, J., Schmuck, G., Andreoli, G., & Hosgood, B. (1996). Estimating leaf biochemistry using the PROSPECT leaf optical properties model. *Remote Sensing of Environment*, 56(3), 194 – 202.
- Jervis, F. X. & Rein, G. (2016). Experimental study on the burning behaviour of pinus halepensis needles using small-scale fire calorimetry of live, aged and dead samples. *Fire and Materials*, 40(3), 385–395.
- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833–3845.
- Jolly, W. M. (2007). Sensitivity of a surface fire spread model and associated fire behaviour fuel models to changes in live fuel moisture. *International Journal of Wildland Fire*, 16(4), 503–509.
- Jonckheere, I., Fleck, S., Nackaerts, K., Muys, B., Coppin, P., Weiss, M., & Baret, F. (2004). Review of methods for in situ leaf area index determination: Part i. theories, sensors and hemispherical photography. *Agricultural and forest meteorology*, 121(1), 19–35.
- JPL-CIT (2015). Mission: MISR Instrument. NASA - Jet Propulsion Lab. Obtenida el 21 de Junio de 2015, desde: <https://www-misr.jpl.nasa.gov/Mission/misrInstrument/>.

- JRC (2011). NDWI: Normalized Difference Water Index. Obtenido el 6 de Septiembre de 2015, desde: http://edo.jrc.ec.europa.eu/documents/factsheets/factsheet_ndwi.pdf.
- JRC (2015). EFFIS - European Forest Fire Information System. Obtenido el 18 de Junio de 2015, desde: <http://forest.jrc.ec.europa.eu/effis/>.
- Jurdao, S., Yebra, M., Guerschman, J. P., & Chuvieco, E. (2013). Regional estimation of woodland moisture content by inverting radiative transfer models. *Remote Sensing of Environment*, 132, 59 – 70.
- Jurdao, S., Yebra, M., Oliva, P., & Chuvieco, E. (2014). Laboratory measurements of plant drying. *Photogrammetric Engineering & Remote Sensing*, 80(5), 451–459.
- Kaufman, Y. J. & Tanre, D. (1992). Atmospherically resistant vegetation index (arvi) for eos-modis. *IEEE transactions on Geoscience and Remote Sensing*, 30(2), 261–270.
- Keane, R. E., Burgan, R., & van Wagtenonk, J. (2001). Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. *International Journal of Wildland Fire*, 10(4), 301–319.
- Keetch, J. J. & Byram, G. M. (1968). A drought index for forest fire control. *Res. Pap. SE-38. Asheville, NC: US Department of Agriculture, Forest Service, Southeastern Forest Experiment Station. 35 p., 38.*
- KERN (2016). Balanza de precisión pfb. *Balanza de precisión de indicación rápida de manejo cómodo y aprobación de homologación*. Obtenida el 3 de Octubre de 2016, desde: <https://www.kern-sohn.com/shop/es/balanzas-de-laboratorio/balanzas-de-precision/PFB/>.
- Key, C. & Benson, N. (2002). Landscape assessment, in fire effects monitoring (FIREMON) and inventory protocol: Integration of standardized field data collection techniques and sampling design with remote sensing to assess fire effects. *NPS-USGS National Burn Severity Mapping Project*.
- Key, C. & Benson, N. (2006). Landscape assessment: ground measure of severity, the Composite Burn Index. Pages LA8–LA15 in DC Lutes, editor. *FIREMON: Fire Effects Monitoring and Inventory System. USDA Forest Service, Rocky Mountain Research Station, Fort Collins, Colorado, USA*.
- King, M. D., Kaufman, Y. J., Tanré, D., & Nakajima, T. (1999). Remote sensing of tropospheric aerosols from space: Past, present, and future. *Bulletin of the American Meteorological society*, 80(11), 2229–2259.
- Knipling, E. B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, 1(3), 155–159.
- Kruse, F. A., Lefkoff, A. B., & Dietz, J. B. (1993). Expert system-based mineral mapping in northern death valley, California/Nevada, using the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). *Remote Sensing of Environment*, 44(23), 309–336.
- Kuusik, A. (1985). The hot-spot effect of a uniform vegetative cover. *Soviet Journal of Remote Sensing*, 3(4), 645 – 658.
- le Maire, G., François, C., Soudani, K., Berveiller, D., Pontailier, J.-Y., Bréda, N., Genet, H., Davi, H., & Dufrêne, E. (2008). Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment*, 112(10), 3846–3864.
- le Maire, G., François, C., & Dufrêne, E. (2004). Towards universal broad leaf chlorophyll indices using {PROSPECT} simulated database and hyperspectral reflectance measurements. *Remote Sensing of Environment*, 89(1), 1 – 28.

- Leblon, B. (2001). Forest wildfire hazard monitoring using remote sensing: A review. *Remote Sensing Reviews*, 20(1), 1–43.
- Levin, N. (1999). *Fundamentals of Remote Sensing*. Tel Aviv University, Israel: GIS unit, the Society for the Protection of Nature in Israel.
- Lichtenthaler, H. K. (1987). Chlorophylls and carotenoids: Pigments of photosynthetic biomembranes. In *Plant Cell Membranes*, volume 148 of *Methods in Enzymology* (pp. 350 – 382). Academic Press.
- Lillesaeter, O. (1982). Spectral reflectance of partly transmitting leaves: laboratory measurements and mathematical modeling. *Remote Sensing of Environment*, 12(3), 247–254.
- Liu, Q., Liang, S., Xiao, Z., & Fang, H. (2014). Retrieval of leaf area index using temporal, spectral, and angular information from multiple satellite data. *Remote Sensing of Environment*, 145, 25–37.
- Liu, S., Peng, Y., Du, W., Le, Y., & Li, L. (2015). Remote estimation of leaf and canopy water content in winter wheat with different vertical distribution of water-related properties. *Remote Sensing*, 7(4), 4626.
- Loomis, R. M. & Main, W. A. (1980). Comparing jack pine slash and forest floor moisture contents and National Fire Danger Rating System predictions. United States Department of Agriculture (USDA), Forest Service, Research Paper NC–189. North Central Forest Experiment Station, St. Paul, Minnesota. 10 p.
- LPDAAC (2014). Leaf Area Index – Fraction of Photosynthetic Active Radiation 8–Day L4 Global 1km. *Land Process Distributed Active Archive Center, NASA & USGS*. Obtenida el 27 de febrero de 2016, desde: https://lpdaac.usgs.gov/dataset_discovery/modis/modis_products_table/mod15a2.
- MAGRAMA (2012). Los Incendios Forestales en España: Decenio 2001-2010. Obtenido el 11 de Octubre de 2015 desde: http://www.magrama.gob.es/es/biodiversidad/estadisticas/incendios_forestales_espa%C3%B1a_decenio_2001_2010_tcm7-235361.pdf.
- Main, R., Cho, M. A., Mathieu, R., O’Kennedy, M. M., Ramoelo, A., & Koch, S. (2011). An investigation into robust spectral indices for leaf chlorophyll estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), 751–761.
- Martínez, J., Vega-García, C., & Chuvieco, E. (2009). Human-caused wildfire risk rating for prevention planning in Spain. *Journal of Environmental Management*, 90(2), 1241–1252.
- Martín, L. E. & Lara, C. H. (1989). Inflamabilidad y energía de las especies de sotobosque. *Instituto Nacional de Investigaciones Agrarias, Ministerios de agricultura, Pesca y Alimentación, Madrid*.
- Martínez, C. L. & Scavuzzo, M. (2015). Joint GRSS/CIREN Workshop on Remote Sensing and its Applications. SAR basics, polarimetry and applications. *IEEE-GRSS y CIREN: Centro de información de recursos naturales*. Workshop asistido el 8 y 9 de Octubre, Santiago - Chile.
- Martínez, J. (2001). Análisis de la distribución espacial de la ocurrencia de incendios forestales en España: patrones de incidencia y causalidad. Master’s thesis, Memoria de Licenciatura. Departamento de Geografía, Universidad de Alcalá.
- Masgrau, L. R. (2004). Los mapas de riesgo de inundaciones: representación de la vulnerabilidad y aportación de las innovaciones tecnológicas. *Documento de Análisis. Geográfico.*, 43, 153–171.
- Massada, A. B., Radeloff, V. C., Stewart, S. I., & Hawbaker, T. J. (2009). Wildfire risk in the wildland–urban interface: a simulation study in northwestern wisconsin. *Forest Ecology and Management*, 258(9), 1990–1999.

- Mather, P. M. (1998). *Computer Processing of Remotely Sensed Images*. Chichester, John Wiley & Sons.
- Matsushita, B., Yang, W., Chen, J., Onda, Y., & Qiu, G. (2007). Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. *Sensors*, 7(11), 2636–2651.
- Mattar, C., Hernández, J., Santamaría-Artigas, A., Durán-Alarcón, C., Olivera-Guerra, L., Inzunza, M., Tapia, D., & Escobar-lavín, E. (2014). A first in-flight absolute calibration of the Chilean earth observation satellite. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 16–25.
- McAllister, S., Grenfell, I., Hadlow, A., Jolly, W. M., Finney, M., & Cohen, J. (2012). Piloted ignition of live forest fuels. *Fire Safety Journal*, 51, 133–142.
- McKinley, R. A., Chine, E. P., & Werth, L. F. (1985). Operational fire fuels mapping with NOAA-AVHRR data.
- Memmert (2016). Universal Oven UN30. Obtenida el 3 de Octubre de 2016, desde: <https://www.memmert.com/products/heating-drying-ovens/universal-oven/UN30/>.
- Miller, W. A. & Johnston, D. C. (1985). Comparison of fire fuel maps produced using MSS and AVHRR data. *Pecora 10 Symposium*, (pp. 305–314).
- Ministerio de Agricultura (2017). Coyuntura Agroclimática. *Sub Departamento de Información, Monitoreo y Prevención (IMP), Ministerio de Agricultura*. Informe obtenido el 27 de Marzo de 2017 desde CIREN (Centro de Información de Recursos Naturales – Área de Procesamiento de Imágenes y Modelamiento).
- Mishra, S. & Mishra, D. R. (2012). Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. *Remote Sensing of Environment*, 117(0), 394–406.
- Miura, T., Huete, A. R., Leeuwen, W. J. D., & Didan, K. (1998). Vegetation detection through smoke-filled AVIRIS images: An assessment using MODIS band passes. *Journal of Geophysical Research: Atmospheres (1984-2012)*, 103(D24), 32001–32011.
- Mobasheri, M. R. & Fatemi, S. B. (2013). Leaf Equivalent Water Thickness assessment using reflectance at optimum wavelengths. *Theoretical and Experimental Plant Physiology*, 25, 196 – 202.
- Moorthy, I., Miller, J. R., Zarco-Tejada, P. J., & Noland, T. L. (2004). Needle Chlorophyll Content Estimation: A Comparative Study of PROSPECT and LIBERTY.
- Muñoz-Feucht, K., Fuentes, A., & Consalvi, J.-L. (2014). Soot volume fraction measurements in a forest fuel layer. *Experimental Thermal and Fluid Science*, 56, 61–68.
- Máximo, A. & Alvarenga, B. (2008). *Física General*, volume 4. Oxford University Press.
- Myneni, R., Hoffman, S., Knyazikhin, Y., Privette, J., Glassy, J., Tian, Y., Wang, Y., Song, X., Zhang, Y., Smith, G., *et al.* (2002). Global products of vegetation leaf area and fraction absorbed par from year one of modis data. *Remote sensing of environment*, 83(1), 214–231.
- Myneni, R. & T.Park, Y. K. (2015). MCD15A2H MODIS/Terra+Aqua Leaf Area Index/F-PAR 8-day L4 Global 500m SIN Grid V006. NASA EOSDIS Land Processes DAAC. <https://doi.org/10.5067/MODIS/MCD15A2H.006>.
- Nagler, P. L., Daughtry, C. S. T., & Goward, S. N. (2000). Plant Litter and Soil Reflectance. *Remote Sensing of Environment*, 71(2), 207–215.

- NASA (2003). Sensor Specifications: Ikonos. Obtenida el 14 de febrero de 2016, desde: <http://geo.arc.nasa.gov/sge/health/sensor/sensors/ikonos.html#spec>.
- NASA (2011). Landsat 7: Science Data User Handbook. Obtenido el 27 de febrero de 2016, desde: http://landsathandbook.gsfc.nasa.gov/data_properties/prog_sect6_5.html.
- NASA (2013). Advanced Very High Resolution Radiometer - AVHRR. Obtenida el 13 de Junio de 2015, desde: <http://noaasis.noaa.gov/NOAASIS/ml/avhrr.html>.
- NASA (2015a). The enhanced thematic mapper plus. Obtenida el 28 de Octubre de 2015, Ver la información del sensor [aquí](#).
- NASA (2015b). Explorer-I and Jupiter-C: The First United States Satellite and Space Launch Vehicle. Obtenida el 18 de Junio de 2015, desde: <http://history.nasa.gov/sputnik/expinfo.html>.
- NASA (2015c). MODIS: Specifications. Obtenida el 21 de Junio de 2015, desde: <http://modis.gsfc.nasa.gov/about/specifications.php>.
- National Climate Assessment (2016). Climate Change Impacts in the United States. *GlobalChange.gov – U.S. Global Change Research Program*. Obtenido el 24 de Junio de 2016, desde: <http://nca2014.globalchange.gov/highlights/overview/climate-trends#intro-section-2>.
- Norman, J. M. & Campbell, G. S. (1989). *Plant Physiological Ecology. Field Methods and Instrumentation*. Chapman and Hall: New York, USA; pp. 301–325.
- OceanOptics (2016a). HR400 and HR4000CG-UV-NIR Series Spectrometers – Installation and Operation Manual. Document: 210-00000-000-02-201604. Obtenido el 3 de Julio de 2016, desde: <http://oceanoptics.com/wp-content/uploads/hr4000.pdf>.
- OceanOptics (2016b). Light sources. Obtenida el 3 de Julio de 2016, desde: <http://oceanoptics.com/product-category/light-sources/>.
- OceanOptics (2016c). STS–NIR. Obtenida el 10 de Abril de 2016, desde: <http://oceanoptics.com/product/sts-nir-microspectrometer/>.
- OceanOptics (2016d). What is the field of view (FOV) of Ocean Optics optical fibers? Obtenida el 07 de Abril de 2016, desde: <http://oceanoptics.com/faq/field-view-fov-ocean-optics-optical-fibers/>.
- OceanOptics (2016e). WS-1 Reflectance Standards. Obtenida el 27 de Marzo de 2016, desde: <http://oceanoptics.com/product/ws-1-reflectance-standards/>.
- Ollinger, S. (2011). Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), 375–394.
- Omi, P. N. (2005). *Forest fires: A reference handbook*. Santa Barbara, California: ABC-CLIO.
- ONEMI (2016). Misión y visión. *Oficina Nacional de Emergencias del Ministerio del Interior y de Salud Pública*. Obtenida el 24 de Junio de 2016, desde: <http://www.onemi.cl/mision-y-vision/>.
- OpticLeaf (2015a). LOPEX93, ANGERS and Leaf BRDF databases. *OPTICLEAF, The database on leaf optical properties*. Obtenida el 8 de Diciembre de 2015, Ver las bases de dato en: <http://opticleaf.ipgp.fr/index.php?page=database>.
- OpticLeaf (2015b). PROSPECT: Inputs for simulation. *OPTICLEAF, The database on leaf optical properties*. Obtenida el 8 de Diciembre de 2015, desde: <http://opticleaf.ipgp.fr/index.php?page=prospect>.

- OpticLeaf (2015c). References of OPTICLEAF, PROSPECT, LOPEX93. *OPTICLEAF: The database on leaf optical properties*. Obtenida el 8 de Diciembre de 2015, desde: <http://opticleaf.ipgp.fr/index.php?page=home>.
- Peñuelas, J., Filella, I., Biel, C., Serrano, L., & Savé, R. (1993). The reflectance at the 950-970 nm region as an indicator of plant water status. *International Journal of Remote Sensing*, 14(10), 1887–1905.
- Peñuelas, J., Piñol, J., Ogaya, R., & Filella, I. (1997). Estimation of plant water concentration by the reflectance Water Index WI (R900/R970). *International Journal of Remote Sensing*, 18(13), 2869–2875.
- Peterson, S. H., Roberts, D. A., & Dennison, P. E. (2008). Mapping live fuel moisture with {MODIS} data: A multiple regression approach. *Remote Sensing of Environment*, 112(12), 4272 – 4284.
- Piñol, J., Filella, I., Ogaya, R., & Peñuelas, J. (1998). Ground-based spectroradiometric estimation of live fine fuel moisture of Mediterranean plants. *Agricultural and Forest Meteorology*, 90(3), 173–186.
- Pinter Jr, P. J., Jackson, R. D., Elaine Ezra, C., & Gausman, H. W. (1985). Sun-angle and canopy-architecture effects on the spectral reflectance of six wheat cultivars. *International Journal of Remote Sensing*, 6(12), 1813–1825.
- Pinty, B., Jung, M., Kaminski, T., Lavergne, T., Mund, M., Plummer, S., Thomas, E., & Widlowski, J.-L. (2011). Evaluation of the jrc-tip 0.01 products over a mid-latitude deciduous forest site. *Remote Sensing of Environment*, 115(12), 3567–3581.
- Planae.ca (2015). Glycine max (L). *Le Répertoire des Plantes*. Obtenida el 9 de Diciembre de 2015, <http://www.planae.ca/Fabaceae%3EFaboideae/Glycine/max/1298.html>.
- PROTA4U (2015). Lactuca sativa l. Obtenida el 8 de Diciembre de 2015, <http://www.prota4u.org/protav8.asp?g=pe&p=Lactuca+sativa+L>.
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126.
- Qi, Y., Dennison, P. E., Spencer, J., & Riaño, D. (2012). Monitoring Live Fuel Moisture Using Soil Moisture and Remote Sensing Proxies. *The Journal of the Association for Fire Ecology*, 8(3), 71–87.
- Radeloff, V. C., Hammer, R. B., Voss, P. R., Hagen, A. E., Field, D. R., & Mladenoff, D. J. (2001). Human Demographic Trends and Landscape Level Forest Management in the Northwest Wisconsin Pine Barrens. *Forest Service - Society of American Foresters*, Volume 47,(2), pp. 229–241(13).
- RAE (2015). Definición: Silvicultura. Obtenido el 13 de Julio de 2015, desde: <http://buscon.rae.es/drae/srv/search?id=sUAYHPJvcDXX2UOCn1hE>.
- Raudino, A., Sarpietro, M. G., & Pannuzzo, M. (2011). The thermodynamics of simple biomembrane mimetic systems. *Journal of Pharmacy And Bioallied Sciences*, 3(1), 15.
- Rautiainen, M. (2005). The spectral signature of coniferous forests: the role of stand structure and leaf area index. *Academic Dissertation, Department of Forest Ecology, Faculty of Agriculture and Forestry, University of Helsinki*.
- Reszka, P. (2017a). Entrevista personal el día 20 de junio.
- Reszka, P. (2017b). *Large Outdoor Fires and the Built Environment – South American View*. Technical report, Combustion Institute (Chile Section) – Universidad Adolfo Ibañez.

- Reszka, P. & Fuentes, A. (2014). The Great Valparaíso Fire and Fire Safety Management in Chile. *Fire Technology*, 51(4), 753–758.
- Riaño, D., Chuvieco, E., Salas, F. J., Palacios-Orueta, A., & Bastarrica, A. (2002). Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Canadian Journal of Forest Research*, 32(8), 1301–1315.
- Riaño, D., Vaughan, P., Chuvieco, E., Zarco-Tejada, P., & Ustin, S. (2005). Estimation of fuel moisture content by inversion of radiative transfer models to simulate equivalent water thickness and dry matter content: analysis at leaf and canopy level. *Geoscience and Remote Sensing, IEEE Transactions on*, 43(4), 819–826.
- Ridalbolivia (2016). GPS Garmin etrex vista HCx. Obtenida el 1 de Octubre de 2016, desde: http://www.ridalbolivia.com/garmin_gps_etrex_vista_hcx.htm.
- Rivera, J. C. (2012). FASAT-CHARLIE en apoyo a los sistemas de alerta, prevención y control de desastres naturales y/o tecnológicos. *Presentación para la CEPAL.*, (PhD en Ingeniería Aeronáutica - Grupo de Operaciones Espaciales - GOE), 28.
- Rock, B. N., Vogelmann, J. E., Williams, D. L., Vogelmann, A. F., & Hoshizaki, T. (1986). Remote Detection of Forest Damage. *BioScience*, 36(7), 439–445.
- Rock, B. N., Williams, D. L., & Vogelmann, J. E. (1985). Field and airborne spectral characterization of suspected acid deposition damage in red spruce (*Picea rubens*) from Vermont. In *Machine Processing of Remotely Sensed Data Symposium*, Purdue University, Lafayette, IN, pp. 71-81.
- Romero, A., Aguado, I., & Yebra, M. (2012). Estimation of dry matter content in leaves using normalized indexes and PROSPECT model inversion. *International Journal of Remote Sensing*, 33(2), 396–414.
- Rothermel, R. C. (1972). A mathematical model for predicting fire spread in wildland fuels.
- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., & Harlan, J. C. (1973). *Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation*. Texas A & M University, Remote Sensing Center.
- Running, S. W., Loveland, T. R., Pierce, L. L., Nemani, R. R., & Hunt Jr, E. R. (1995). A remote sensing based vegetation classification logic for global land cover analysis. *Remote Sensing of Environment*, 51(1), 39–48.
- SAF (2015). Productos basados en imágenes, procedimiento de descarga de imágenes FASat-C. Obtenido el 12 de Junio de 2015, desde: <http://www.saf.cl/index.php/productos/16-productos/218-imagenes>.
- Salas, F. J. & Chuvieco, E. (1995). Aplicación de imágenes Landsat-TM a la cartografía de modelos combustibles. *Revista de Teledetección*, (pp. 5: 18–28).
- Salas, F. J. & Cocero, D. (2004). In . E. Chuvieco, *Nuevas tecnologías para la estimación del riesgo de incendios forestales*, volume 4 chapter II, (pp. 23–32). España, csic edición.
- San Miguel Ayanz, J., Barbosa, P., Schmuck, G., Libertà, G., & Schulte, E. (2002). Towards a coherent forest fire information system in Europe: The European Forest Fire Information System (EFFIS). In *Forest Fire Research & Wildland Fire Safety*. (D. X. Viegas, Ed.) Rotterdam, Millpress.
- Sandberg, D. V., Ottmar, R. D., & Cushon, G. H. (2001). Characterizing fuels in the 21st Century. *International Journal of Wildland Fire*, 10, 381–387.

- Schoenberg, F. P., Peng, R., Huang, Z., & Rundel, P. (2003). Detection of non-linearities in the dependence of burn area on fuel age and climatic variables. *International Journal of Wildland Fire*, 12(1), 1–6.
- Scott, J. H. & Burgan, R. E. (2005). Standard Fire Behavior Fuel Models: A Comprehensive Set for Use with Rothermel's Surface Fire Spread Model.
- Scott, J. H. & Reinhardt, E. D. (2001). Assessing crown fire potential by linking models of surface and crown fire behavior. *USDA Forest Service Research Paper RMRS-RP-29*, (pp.66).
- Sellers, P. J. (1985). Canopy reflectance, photosynthesis and transpiration. *International Journal of Remote Sensing*, 6(8), 1335–1372.
- Senado de la República de Chile (2015). Urgen modernizar el sistema de emergencia de nuestro país. *Senado de la República de Chile – Prensa Parlamentaria*. Obtenido el 24 de Junio de 2016, desde: http://www.senado.cl/urgen-modernizar-el-sistema-de-emergencia-de-nuestro-pais/prontus_senado/2015-03-16/140141.html.
- Serbin, G., Hunt, E. R., Daughtry, C. S. T., McCarty, G. W., & Doraiswamy, P. C. (2009). An improved ASTER index for remote sensing of crop residue. *Remote Sensing*, 1(4), 971–991.
- Serrano, L., Peñuelas, J., & Ustin, S. L. (2002). Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals. *Remote Sensing of Environment*, 81(2), 355–364.
- Shen, Y., Shi, R., Niu, Z., & Yan, C. (2005). Estimation models for vegetation water content at both leaf and canopy levels. In *Geoscience and Remote Sensing Symposium, 2005. IGARSS '05. Proceedings. 2005 IEEE International*, volume 2 (pp. 1387–1389).
- Simard, A. & Main, W. (1982). Comparing methods of predicting jack pine slash moisture. *Canadian Journal of Forest Research*, 12(4), 793–802.
- Simeoni, A., Thomas, J., Bartoli, P., Borowieck, P., Reszka, P., Colella, F., Santoni, P.-A., & Torero, J. L. (2012). Flammability studies for wildland and wildland–urban interface fires applied to pine needles and solid polymers. *Fire safety journal*, 54, 203–217.
- Sims, D. A., Rahman, A. F., Cordova, V. D., El-Masri, B. Z., Baldocchi, D. D., Bolstad, P. V., Flanagan, L. B., Goldstein, A. H., Hollinger, D. Y., Misson, L., Monson, R. K., Oechel, W. C., Schmid, H. P., Wofsy, S. C., & Xu, L. (2008). A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. *Remote Sensing of Environment*, 112(4), 1633–1646.
- Sims, D. A., Rahman, A. F., Cordova, V. D., El-Masri, B. Z., Baldocchi, D. D., Flanagan, L. B., Goldstein, A. H., Hollinger, D. Y., Misson, L., Monson, R. K., Oechel, W. C., Schmid, H. P., Wofsy, S. C., & Xu, L. (2006). On the use of MODIS EVI to assess gross primary productivity of North American ecosystems. *Journal of Geophysical Research: Biogeosciences*, 111(G04015).
- Sims, D. A., Rahman, A. F., Vermote, E. F., & Jiang, Z. (2011). Seasonal and inter-annual variation in view angle effects on MODIS vegetation indices at three forest sites. *Remote Sensing of Environment*, 115(12), 3112–3120.
- Sobrino, J. A. (2000). *Teledetección*. España: Publicaciones de la Universitat de València, 1° edición.
- Sow, M., Mbow, C., Hély, C., Fensholt, R., & Sambou, B. (2013). Estimation of Herbaceous Fuel Moisture Content Using Vegetation Indices and Land Surface Temperature from MODIS Data. *Remote Sensing*, 5(6), 2617.

- SPOT-Vegetation (2015). Vegetation Programme.
- Stow, D., Madhura, N., & Kaiser, J. (2006). Time series of chaparral live fuel moisture maps derived from MODIS satellite data. *International Journal of Wildland Fire*, 15, 347–360.
- Stow, D., Niphadkar, M., & Kaiser, J. (2005). MODIS-derived visible atmospherically resistant index for monitoring chaparral moisture content. *International Journal of Remote Sensing*, 26(17), 3867–3873.
- Teledet (2016). Procesamiento de las imágenes satelitales. Obtenida el 14 de Noviembre de 2016, desde: <http://www.teledet.com.uy/tutorial-imagenes-satelitales/procesamiento-imagenes-satelitales-1.htm>.
- Theobald, D. M. & Romme, W. H. (2007). Expansion of the US wildland–urban interface. *Landscape and Urban Planning*, 83(4), 340–354.
- Trabaud, L. (1976). Inflammabilité et combustibilité des principales espèces des garrigues de la région méditerranéenne. *Oecol Plant*.
- Trombetti, M., Riaño, D., Rubio, M., Cheng, Y., & Ustin, S. (2008). Multi-temporal vegetation canopy water content retrieval and interpretation using artificial neural networks for the continental {USA}. *Remote Sensing of Environment*, 112(1), 203 – 215.
- Trujillo, R. (2015). SSOT: Historia y características del satélite. (Presentación de cátedra: Teledetección Satelital, 13 de Mayo 2015), pp. 28.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150.
- Tucker, C. J. (1980). Remote sensing of leaf water content in the near infrared. *Remote Sensing of Environment*, 10(1), 23–32.
- TVN (2014). Así se ve el daño del incendio en valparaíso vía satélite. *TVN – 24horas.cl*. Obtenida el 27 de Junio de 2016, desde: <http://www.24horas.cl/nacional/asi-se-ve-el-dano-del-incendio-en-valparaiso-via-satelite-1180509>.
- UCSUSA (2015). UCS Satellite Database. *Union of Concerned Scientists – Science for a healthy planet and safer world*. Obtenido el 13 de Febrero de 2016, desde: http://www.ucsusa.org/nuclear-weapons/space-weapons/satellite-database#.Vr_MSPnhCUk.
- Ullah, S., Skidmore, A. K., Ramoelo, A., Groen, T. A., Naeem, M., & Ali, A. (2014). Retrieval of leaf water content spanning the visible to thermal infrared spectra. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 56–64.
- Underwood, C. I., Valenzuela, A., Schoenherr, M., Arancibia, M., & Fouquet, M. (2003). *Initial in-orbit results from a low-cost atmospheric ozone monitor operating on board the FASat-Bravo microsatellite*, volume 361. Obtenido el 20 de Julio de 2015, desde: <http://rsta.royalsocietypublishing.org/roypta/361/1802/71.full.pdf>.
- UNESCO (2012). Análisis de rriesgo de desastres en Chile. VII Plan de acción dipecho en Sudamérica 2011–2012. Obtenido el 24 de Junio de 2016, desde: <http://www.eird.org/wikiesp/images/Analisisriesgosdedesastreschiledipechovii.pdf>.
- UNISDR (2015). Global assessment report on disaster risk reduction. United Nations.
- USDA (2002). Plant guide: Monterrey pine – pinus radiata. *United States Department of Agriculture*. Obtenida el 22 de Septiembre de 2016, desde: https://plants.usda.gov/plantguide/pdf/cs_pira2.pdf.

- USDA-FS (2015a). Remote Sensing Applications Center - Programs and Services. Obtenida el 14 de Junio de 2015, desde: <http://www.fs.fed.us/eng/rsac/programs/list.html>.
- USDA-FS (2015b). The Fuel Characteristic Classification System. Obtenida el 14 de Junio de 2015, desde: <http://www.fs.fed.us/pnw/fera/fft/fccsmodule.shtml>.
- USDA-FS (2015c). WFAS: Wildland Fire Assessment System. Obtenida el 14 de Junio de 2015, desde: <http://www.wfas.net/>.
- USGS (2015a). Landsat 8. Obtenida el 21 de Junio de 2015, desde: <http://landsat.usgs.gov/landsat8.php> y http://landsat.usgs.gov/about_ldcm.php.
- USGS (2015b). Using the USGS Landsat 8 Product. *United States Geological Survey*. Obtenida el 14 de Noviembre de 2016, desde: http://landsat.usgs.gov/Landsat8_Using_Product.php.
- USGS (2016). FAQ About Landsat Missions: bands specification. Obtenida el 13 de Noviembre de 2016, desde: http://landsat.usgs.gov/band_designations_landsat_satellites.php.
- Ustin, S. L., Riaño, D., & Hunt, E. R. (2012). Estimating canopy water content from spectroscopy. *Israel Journal of Plant Sciences*, 60(1-2), 9–23.
- Ustin, S. L., Roberts, D. A., Pinzón, J., Jacquemoud, S., Gardner, M., Scheer, G., Castañeda, C. M., & Palacios-Orueta, A. (1998). Estimating Canopy Water Content of Chaparral Shrubs Using Optical Methods. *Remote Sensing of Environment*, 65(3), 280–291.
- Valette, J. (1986). Inflammabilité, teneur en eau et turgescence relative de quatre espèces forestières méditerranéennes. In *Seminar on Methods and Equipment for the Prevention of Forest Fires. Valencia (Spain). 30 Sep-4 Oct 1986*.
- Van Deventer, A. P., Ward, A. D., Gowda, P. H., & Lyon, J. G. (1997). Using Thematic Mapper data to identify contrasting soil plains and tillage practices. *Photogrammetric Engineering and Remote Sensing*, 63, 87–93.
- Van Wagner, C. *et al.* (1967). Seasonal variation in moisture content of eastern canadian tree foliage and the possible effect on crown fires. Publication No. 1204.
- Van Wagner, C. E. (1987). Development and Structure of the Canadian Forest Fire Weather Index System.
- Van Wagendonk, J. W. (1997). Use of thematic mapper imagery to map fuel models.
- Van Wagendonk, J. W. & Root, R. R. (2003). The use of multi-temporal Landsat Normalized Difference Vegetation Index (NDVI) data for mapping fuel models in Yosemite National Park, USA. *International Journal of Remote Sensing*, 24(8), 1639–1651.
- Vaughan, P. (2001). Estimación de contenido de humedad de la vegetación mediante espectroradiometría. Trabajo de investigación tutelado, Universidad de Alcalá, Alcalá de Henares, Spain.
- Veraverbeke, S., Lhermitte, S., Verstraeten, W., & Goossens, R. (2010a). The temporal dimension of differenced Normalized Burn Ratio (dNBR) fire/burn severity studies: the case of the large 2007 Peloponnese wildfires in Greece. *Remote Sensing of Environment*, 114(11), 2548–2563.
- Veraverbeke, S., Verstraeten, W. W., Lhermitte, S., & Goossens, R. (2010b). Illumination effects on the differenced normalized burn ratio's optimality for assessing fire severity. *International Journal of Applied Earth Observation and Geoinformation*, 12(1), 60–70.
- Verhoef, W. (1984). Light scattering by leaf layers with application to canopy reflectance modeling: the sail model. *Remote sensing of environment*, 16(2), 125–141.

- Verrelst, J., Schaepman, M. E., Koetz, B., & Kneubühler, M. (2008). Angular sensitivity analysis of vegetation indices derived from CHRIS/PROBA data. *Remote Sensing of Environment*, 112(5), 2341–2353.
- Viegas, D., Piñol, J., Viegas, M., & Ogaya, R. (1998). Moisture content of living forest fuels and their relationship with meteorological indices in the Iberian Peninsula. In *3rd International Conference on Forest Fire Research and 14th Conference on Fire and Forest Meteorology, Coimbra, Portugal* (pp. 16–20).
- Viegas, D. X., Ferreira, A. D., & Viegas, M. T. (1992). Moisture content of fine forest fuels and fire occurrence in central Portugal. *International Journal of Wildland Fire*, 2(2), 69–86.
- Viegas, D. X., Piñol, J., Viegas, M. T., & Ogaya, R. (2001). Estimating live fine fuels moisture content using meteorologically-based indices. *International Journal of Wildland Fire*, 10(2), 223–240.
- Viney, N. R. (1991). A review of fine fuel moisture modelling. *International Journal of Wildland Fire*, 1(4), 215–234.
- Viney, N. R. & Hatton, T. J. (1989). Assessment of existing fine fuel moisture models applied to eucalyptus litter. *Australian Forestry*, 52(2), 82–93.
- Wang, L., Hunt, J. E. R., Qu, J. J., Hao, X., & Daughtry, C. S. T. (2011a). Towards estimation of canopy foliar biomass with spectral reflectance measurements. *Remote Sensing of Environment*, 115(3), 836–840.
- Wang, L., Hunt Jr, E. R., Qu, J. J., Hao, X., & Daughtry, C. S. T. (2013). Remote sensing of fuel moisture content from ratios of narrow-band vegetation water and dry-matter indices. *Remote Sensing of Environment*, 129(0), 103–110.
- Wang, L. & Qu, J. J. (2007). NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. *Geophysical Research Letters*, 34(20).
- Wang, L., Qu, J. J., & Hao, X. (2008). Forest fire detection using the normalized multi-band drought index (NMDI) with satellite measurements. *Agricultural and Forest Meteorology*, 148(11), 1767–1776.
- Wang, L., Qu, J. J., Hao, X., & Hunt, E. R. (2011b). Estimating dry matter content from spectral reflectance for green leaves of different species. *International Journal of Remote Sensing*, 32(22), 7097–7109.
- Watson, D. (1947). Comparative physiological studies on the growth of field crops: II. The effect of varying nutrient supply on net assimilation rate and leaf area. *Annals of Botany*, 11(44), 375–407.
- Weise, D. R., Hartford, R. A., & Mahaffey, L. (1998). Assessing live fuel moisture for fire management applications. In: *Fire in ecosystem management: Shifting the paradigm from suppression to prescription*; T. L. Pruden & L. A. Brennan (Eds.). Proceedings from the 20th Florida Tall Timbers Fire Ecology Conference, 7–10 May 1996, Boise, ID (pp. 49-55). Tallahassee, FL: Tall Timbers Research Station.
- Westman, W. E. & Price, C. V. (1988). Spectral changes in conifers subjected to air pollution and water stress: experimental studies. *IEEE Transactions on Geoscience and Remote Sensing*, 26, 11–20.
- Xanthopoulos, G. & Wakimoto, R. H. (1993). A time to ignition-temperature-moisture relationship for branches of three western conifers. *Canadian Journal of Forest Research*, 23(2), 253–258.
- Yang, W., Shabanov, N., Huang, D., Wang, W., Dickinson, R., Nemani, R., Knyazikhin, Y., & Myneni, R. (2006). Analysis of leaf area index products from combination of MODIS Terra and Aqua data. *Remote Sensing of Environment*, 104(3), 297–312.

- Yebra, M. (2008). *Estimación de contenido de humedad de vegetación mediterránea a partir de imágenes MODIS*. PhD thesis, Departamento de Geografía. Alcalá de Henares: Universidad de Alcalá, 202.
- Yebra, M., Chuvieco, E., & Aguado, I. (2008a). Comparación entre modelos empíricos y de transferencia radiativa para estimar contenido de humedad en pastizales: Poder de generalización. *Revista de teledetección*, 29, 73–90.
- Yebra, M., Chuvieco, E., & Riaño, D. (2008b). Estimation of live fuel moisture content from MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*, 148(4), 523–536.
- Yebra, M., Dennison, P. E., Chuvieco, E., Riaño, D., Zylstra, P., Hunt Jr, E. R., Danson, F. M., Qi, Y., & Jurdao, S. (2013). A global review of remote sensing of live fuel moisture content for fire danger assessment: Moving towards operational products. *Remote Sensing of Environment*, 136(0), 455–468.
- Yilmaz, M. T., Hunt Jr, E. R., & Jackson, T. J. (2008a). Remote sensing of vegetation water content from equivalent water thickness using satellite imagery. *Remote Sensing of Environment*, 112(5), 2514–2522.
- Yilmaz, M. T., Jr., E. R. H., Goins, L. D., Ustin, S. L., Vanderbilt, V. C., & Jackson, T. J. (2008b). Vegetation water content during SMEX04 from ground data and Landsat 5 Thematic Mapper imagery. *Remote Sensing of Environment*, 112(2), 350 – 362. Soil Moisture Experiments 2004 SMEX04 Special Issue.
- Young, H. D., Freedman, R. A., & Ford, A. L. (2009). *Física Universitaria con Física Moderna*, volume 2. Pearson Educación de México, S.A.
- Yuan, F., Sawaya, K. E., Loeffelholz, B. C., & Bauer, M. E. (2005). Land cover classification and change analysis of the twin cities (minnesota) metropolitan area by multitemporal landsat remote sensing. *Remote sensing of Environment*, 98(2), 317–328.
- Zahn, S. & Hensen, C. (2011). *A Synthesis of Fuel Moisture Collection Methods and Equipments – A Desk Guide*. Technical report, U.S. Department of Agriculture - Forest Service. 5100–Fire Management; 1151 1806–SDTDC.
- Zarco-Tejada, P. J., Rueda, C. A., & Ustin, S. L. (2003). Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*, 85(1), 109–124.
- Zhang, F., Zhang, L.-W., Shi, J.-J., & Huang, J.-F. (2014a). Soil Moisture Monitoring Based on Land Surface Temperature-Vegetation Index Space Derived from MODIS Data. *Pedosphere*, 24(4), 450–460.
- Zhang, G., Ganguly, S., Nemani, R. R., White, M. A., Milesi, C., Hashimoto, H., Wang, W., Saatchi, S., Yu, Y., & Myneni, R. B. (2014b). Estimation of forest aboveground biomass in california using canopy height and leaf area index estimated from satellite data. *Remote Sensing of Environment*, 151, 44–56.
- Zhang, J.-H., Yao, F.-M., Liu, C., Yang, L.-M., & Boken, V. K. (2011a). Detection, Emission Estimation and Risk Prediction of Forest Fires in China Using Satellite Sensors and Simulation Models in the Past Three Decades- An Overview. *International Journal of Environmental Research and Public Health*, 8(8), 3156.
- Zhang, Q., Li, Q., & Zhang, G. (2011b). Scattering impact analysis and correction for leaf biochemical parameter estimation using vis-nir spectroscopy. *Spectroscopy*, 26(7), 28–39.

Zheng, G. & Moskal, L. M. (2009). Retrieving leaf area index (LAI) using remote sensing: theories, methods and sensors. *Sensors*, 9(4), 2719–2745.

Anexo

A. Áreas Homogéneas definidas por la CONAF

Tabla A.1: Códigos de las áreas homogéneas de la CONAF.

Áreas Homogéneas		
Código	Atributos área homogénea, sectores SNASPE^a con:	Superficie [ha]
AH1	Probabilidad de ocurrencia de incendios	76,8
AH2	Poblados cercanos y presencia de caminos, senderos o líneas de tren, donde existe probabilidad de ocurrencia de incendios forestales.	1.038,90
AH3	Poblados cercanos, donde existe probabilidad de incendios forestales.	4.619,8
AH4	Cercanos a caminos, senderos o líneas de tren, donde existe probabilidad de ocurrencia de incendios forestales.	0,15
AH5	Poblados cercanos y presencia de caminos, senderos o líneas de tren.	12,73
AH6	Poblados cercanos.	4.466,64
AH7	Cercanos a caminos, senderos o líneas de tren.	384,92
AH8	Sectores SNASPE.	6.669,17
AH9	Sectores cercanos al SNASPE con presencia de poblados y caminos, senderos o líneas de tren, con probabilidad de ocurrencia de incendios forestales.	3.416,75
AH10	Sectores cercanos al SNASPE con presencia de poblados, con probabilidad de ocurrencia de incendios forestales	8.206,52
AH11	Sectores cercanos al SNASPE con presencia de caminos, senderos o líneas de tren, con probabilidad de ocurrencia de incendios forestales.	770,25
AH12	Sectores cercanos al SNASPE, donde existe probabilidad de ocurrencia de incendios forestales.	1.894,35
AH13	Sectores cercanos al SNASPE con presencia de poblados y caminos, senderos o líneas de tren.	787,73
AH14	Sectores cercanos al SNASPE con presencia de poblados.	8.512,62
AH15	Sectores cercanos al SNASPE con presencia de caminos, senderos o líneas de tren.	1.813,29
AH16	Sectores cercanos al SNASPE.	11.466,52
AH17	Sectores cercanos a poblados con presencia de caminos, senderos o líneas de tren, donde existe probabilidad de ocurrencia de incendios forestales.	51.583,58
AH18	Sectores cercanos a poblados, donde existe probabilidad de ocurrencia de incendios forestales.	85.342,40
AH19	Sectores cercanos a caminos, senderos o líneas de tren, donde existe probabilidad de ocurrencia de incendios forestales.	21.597,01
AH20	Sectores donde existe probabilidad de ocurrencia de incendios forestales.	55.934,27
AH21	Sectores cercanos a poblados con presencia de caminos, senderos o líneas de tren.	47.327,43
AH22	Sectores cercanos a poblados.	139.987,78
AH23	Sectores con presencia a caminos, senderos o líneas de tren.	75.848,03
Total		531.751,64

^aSNASPE = Sistema Nacional de Áreas Silvestres Protegidas del Estado.

B. Características de los satélites chilenos

Fasat Alfa

Características FASat–Alfa	Descripción
Categoría	Micro satélite
Dimensiones	36 (largo) x 36 (ancho) x 70 (alto) [cm]
Peso	50 [kg]
Tipo de órbita	baja (<i>low earth orbit</i>)
Período orbital	3–4 vueltas a la tierra en un día.
Vida útil	8 a 10 años.
Carga útil	<ul style="list-style-type: none"> • OLME: Monitoreo capa de ozono. • DTE: Transferencia de datos. • EIS: Sistema de imágenes terrestres. • GPS: Experimento de navegación GPS. • SSDRE: Unidad de almacenamiento de data.
Fecha de lanzamiento	31 de Agosto de 1995.
Adosado a:	Sich – 1.

Tabla B.1: Características del satélite FASat – Alfa.

Fuente: Elaboración propia a partir de [Fernández \(2003\)](#).

Fasat Bravo

Características FASat – Bravo	Descripción
Categoría	Micro satélite
Tiempo de vida	Casi 3 años, dejó de operar en junio de 2001.
Cantidad de órbitas	Realizó 13 mil órbitas alrededor del planeta.
Resultados	<ul style="list-style-type: none"> ○ Obtuvo un total de 1.273 imágenes de Chile. ○ Efectuó mediciones exitosas de ozono.
Carga útil	<ul style="list-style-type: none"> • OLME: Monitoreo capa de ozono. • DTE: Transferencia de datos. • EIS: Sistema de imágenes terrestres. • GPS: Experimento de navegación GPS. • SSDRE: Unidad de almacenamiento de data.
Fecha de lanzamiento	10 de Julio de 1998.
Falla	Baterías.
Adosado a:	Resurs o.

Tabla B.2: Características del satélite FASat – Bravo.

Fuente: Elaboración propia a partir de [Trujillo \(2015\)](#).

Sistema satelital de observación terrestre (SSOT)

Características SSOT	Descripción
Categoría	Astrosat-100
Tipo de órbita	baja, 620[km].
Equipamiento	Telescopio Korsch de tres espejos.
Resolución espacial (GSD <i>Ground Sample Distance</i>) a NADIR	<ul style="list-style-type: none"> ◦ PAN Channel: 1,45 [m] ◦ XS Channel: 5,80 [m]
SWATH (barrido)	10,15 [km]
Cantidad de bandas XS	4 bandas XS (Multi-espectrales)
Rango de longitud de onda	0,45 – 0,89 [μ m]
Período orbital	97,23 [min]
Revista:	
Con $\pm 27^\circ$ Inclinación	5 [días]
Con $\pm 7^\circ$ Inclinación	21 [días]
Con $\pm 3^\circ$ Inclinación	37 [días]
Telemetría	Bi-Banda X-S.

Tabla B.3: Características del satélite FASat – Charlie (SSOT)

Fuente: Elaboración propia a partir de [Trujillo \(2015\)](#).

Tipos de satélites y sensores

En las siguientes cuatro páginas se pueden apreciar cuatro tablas que determinan características de una serie de satélites y sensores. Entre ellos se aprecian el Landsat 8, Quickbird, RapidEye, Aqua & Terra, WorldView 3, entre otros. Cada uno de ellos abarca regiones distintas del espectro en sus bandas, algunos coinciden principalmente en la región del visible y del infrarrojo cercano.

Por otro lado, a modo de resumen, es importante destacar que: R. Espacial se refiere a Resolución Espacial, que R. Temporal se refiere a Resolución Temporal, que R. Radiométrica se refiere a la Resolución Radiométrica y que el *Swath* corresponde al ancho de barrido de la imagen captada por el sensor.

Tabla B.4: Principales características de los sensores.

Sensor	Bandas	Rango λ [μm]	R. Espacial [m]	R. Temporal*	R. Radiométrica [bit]	Swath [km] [†]
Landsat 8 – OLI (USGS, 2015a)	B1: Aerosol	0,435 – 0,451	30			
	B2: Blue	0,452 – 0,512	30			
	B3: Green	0,533 – 0,590	30			
	B4: Red	0,636 – 0,673	30			
	B5: NIR	0,851 – 0,879	30	16 días	16	190
	B6: SWIR-1	1,566 – 1,651	30			
	B7: SWIR-2	2,107 – 2,294	30			
	B8: Panchromatic	0,503 – 0,676	15			
	B9: Cirrus	1,363 – 1,384	30			
– TIRS	B10: TIR-1	10,60 – 11,19	100	16 días	16	190
	B11: TIR-2	11,50 – 12,51	100			
QuickBird [†] (DigitalGlobe, 2015c)	Blue	0,430 – 0,545	2,16			
	Green	0,466 – 0,620	2,16			
	Red	0,590 – 0,710	2,16	2 a 12 días.	11	12
	NIR	0,715 – 0,918	2,16			
	Panchromatic	0,405 – 1,053	0,55			
RapidEye (Dettwiler, 2015)	Blue	0,440 – 0,510	6,5			
	Green	0,520 – 0,590	6,5			
	Red	0,630 – 0,685	6,5	5,5 días	12	77
	Red Edge	0,690 – 0,730	6,5			
	NIR	0,760 – 0,850	6,5			
GeoEye –1 (DigitalGlobe, 2015a)	Blue	0,450 – 0,510	1,65			
	Green	0,510 – 0,580	1,65			
	Red	0,655 – 0,690	1,65	2,6 días a 30° fuera nadir.	11	15,3
	NIR	0,780 – 0,920	1,65			
	Panchromatic	0,450 – 0,800	0,41			

[†] Las características son en base a 400 km de altitud del sensor.

*.† Equivalen a valores en NADIR (90°) a menos que se indique lo contrario.

Tabla B.5: Continuación de Tabla B.4.

Sensor	Bandas	Rango λ [μm]	R. Espacial [m]	R. Temporal*	R. Radiométrica [bit]	Swath [km] [†]
Aqua & Terra MODIS (NASA, 2015c)	B1: Tierra / Aerosol / Nubes	0,620 – 0,670	250	1 día	12	2.330
	B2: Tierra / Aerosol / Nubes	0,841 – 0,876				
	B3: Propiedades	0,459 – 0,479	500	1 día	12	2.330
	B4: Propiedades	0,545 – 0,565				
	B5: Propiedades	1,230 – 1,250				
	B6: Propiedades	1,628 – 1,652				
	B7: Propiedades	2,105 – 2,155				
	B8: Océanos	0,405 – 0,420				
	B9: Océanos	0,438 – 0,448				
	B10: Océanos	0,483 – 0,493	1.000	1 día	12	2.330
	B11: Océanos	0,526 – 0,536				
	B12: Océanos	0,546 – 0,556				
	B13: Océanos	0,662 – 0,672				
	B14: Océanos	0,673 – 0,683				
	B15: Océanos	0,743 – 0,753				
	B16: Océanos	0,862 – 0,877				
	B17: Vapor Atm.	0,890 – 0,920				
	B18: Vapor Atm.	0,931 – 0,941				
	B19: Vapor Atm.	0,915 – 0,965				
Fasat Charlie (Mattar <i>et al.</i> , 2014)	Blue	0,455 – 0,520	5,8	37 días nadir, 3–5 días $\pm 30^\circ$	10	10
	Green	0,528 – 0,588	5,8			
	Red	0,625 – 0,695	5,8			
	NIR	0,758 – 0,881	5,8			
	Panchromatic	0,455 – 0,744	1,45			

*[†] Equivalen a valores en NADIR (90°) a menos que se indique lo contrario.

Tabla B.6: Continuación de [Tabla B.5](#).

Sensor	Bandas	Rango λ [μm]	R. Espacial [m]*	R. Temporal	R. Radiométrica [bit]	Swath [km]†	
WorldView 3 (DigitalGlobe, 2015e)							
- MS	Coastal	0,400 – 0,450	1,24				
	Blue	0,450 – 0,510	1,24				
	Green	0,510 – 0,580	1,24				
	Yellow	0,585 – 0,625	1,24				
	Red	0,630 – 0,690	1,24		11	13,1	
	Red Edge	0,705 – 0,745	1,24	4,5 días a 20° fuera de nadir o menos.			
	NIR-1	0,770 – 0,895	1,24				
	NIR-2	0,860 – 1,040	1,24				
	Panchromatic	0,450 – 0,800	0,31				
	- SWIR	SWIR-1	1,195 – 1,225	3,7			
		SWIR-2	1,550 – 1,590	3,7			
		SWIR-3	1,640 – 1,680	3,7			
		SWIR-4	1,710 – 1,750	3,7		14	13,1
		SWIR-5	2,145 – 2,185	3,7	4,5 días a 20° fuera de nadir o menos.		
SWIR-6		2,185 – 2,225	3,7				
SWIR-7		2,235 – 2,285	3,7				
SWIR-8		2,295 – 2,365	3,7				
- CAVIS	Desert Clouds	0,405 – 0,420	30				
	Aerosol-1	0,459 – 0,509	30				
	Green	0,525 – 0,585	30				
	Aerosol-2	0,635 – 0,685	30				
	Water-1	0,845 – 0,885	30				
	Water-2	0,897 – 0,927	30				
	Water-3	0,930 – 0,965	30				
	NDVI-SWIR	1,220 – 1,252	30				
	Cirrus	1,365 – 1,405	30				
	Snow	1,620 – 1,680	30				
	Aerosol-3	2,105 – 2,245	30	4,5 días a 20° fuera de nadir o menos.	No se encontró información	13,1	

*. † Equivalen a valores en NADIR (90°).

Tabla B.7: Continuación de Tabla B.6.

Sensor	Bandas	Rango λ [μm]	R. Espacial [m] [†]	R. Temporal [‡]	R. Radiométrica [bit]	Swath [km]*
WorldView 2 (DigitalGlobe, 2015d)	Coastal	0,400 – 0,450	1,85			
	Blue	0,450 – 0,510	1,85			
	Green	0,510 – 0,580	1,85			
	Yellow	0,585 – 0,625	1,85			
	Red	0,630 – 0,690	1,85	3,7 días a 20° fuera de nadir o menos.	11	16,4
	Red Edge	0,705 – 0,745	1,85			
	NIR-1	0,770 – 0,895	1,85			
	NIR-2	0,860 – 1,040	1,85			
	Panchromatic	0,450 – 0,800	0,46			
Pleiades 1A-1B (Astrium, 2015)	Blue	0,430 – 0,550	2,0			
	Green	0,500 – 0,620	2,0			
	Red	0,590 – 0,710	2,0	Diario	12	20
	NIR	0,740 – 0,940	2,0			
	Panchromatic	0,470 – 0,830	0,5			
SPOT 6/7 (Astrium, 2015)	Blue	0,450 – 0,520	6,0			
	Green	0,530 – 0,590	6,0			
	Red	0,630 – 0,700	6,0	Diario	12	60
	NIR	0,760 – 0,890	6,0			
	Panchromatic	0,450 – 0,750	1,5			
IKONOS (NASA, 2003) (DigitalGlobe, 2015b)	Blue	0,450 – 0,520	3,2			
	Green	0,520 – 0,600	3,2			
	Red	0,630 – 0,690	3,2	App. 3 días	11	11,3
	NIR	0,760 – 0,900	3,2			
	Panchromatic	0,450 – 0,900	0,82			

*^{†,‡} Equivalen a valores en NADIR (90°), a menos que se indique lo contrario.

C. Calibración imágenes Landsat 8

a) Conversión a radiancia al tope de la atmósfera.

Como se puede apreciar en la [Tabla B.4](#), el satélite Landsat 8 cuenta con 2 sensores: OLI y TIRS. Las bandas de dichos sensores pueden convertirse a valores de radiancia espectral al nivel del techo de la atmósfera (*Top of Atmosphere* – TOA) utilizando factores re-escalados a partir del metadato a partir de la siguiente expresión:

$$L_{\lambda} = M_L \cdot Q_{cal} + A_L \quad (C.1)$$

En donde L_{λ} corresponde a la radiación espectral al tope de la atmósfera en unidades de $W m^{-2} srad^{-1} \mu m^{-1}$, M_L corresponde al factor multiplicador re-escalado para la radiancia, de cada banda, que se encuentra en el metadato. A_L es el factor aditivo re-escalado para la radiancia, de cada banda, que se encuentra en el metadato, y Q_{cal} es el valor del DN. De esta forma ya se torna un tanto tedioso la corrección, que se debe hacer para cada banda del sensor (el sensor OLI trae 9 bandas, por lo que se tienen 9 valores de L_{λ} para dicho sensor).

b) Conversión a reflectancia al tope de la atmósfera.

La información de las imágenes del sensor OLI también se puede convertir a valores de reflectancia al tope de la atmósfera utilizando coeficientes de reflectancia re-escalados a partir de información del metadato. La forma de calcularla es mediante la siguiente expresión:

$$\rho_{\lambda'} = M_{\rho} \cdot Q_{cal} + A_{\rho} \quad (C.2)$$

En donde $\rho_{\lambda'}$ es la reflectancia planetaria al techo de la atmósfera (sin corrección del ángulo solar). M_{ρ} corresponde al factor multiplicador re-escalado para la reflectancia, de cada banda, que se encuentra en el metadato. A_{ρ} es el factor aditivo re-escalado para la reflectancia, de cada banda, que se encuentra en el metadato, y Q_{cal} es el valor del DN. Al igual que para el cálculo de la radiancia en TOA, el valor de la reflectancia planetaria al techo de la atmósfera ($\rho_{\lambda'}$) también se realiza por cada una de las 9 bandas de una imagen del sensor OLI.

Por otro lado, también se puede determinar la reflectancia en TOA con una corrección para el ángulo solar, donde se tiene que:

$$\rho_{\lambda} = \frac{\rho_{\lambda'}}{\cos(\theta_{SZ})} = \frac{\rho_{\lambda'}}{\sin(\theta_{SE})} \quad (C.3)$$

Donde ρ_{λ} es la reflectancia planetaria al techo de la atmósfera, θ_{SE} es el ángulo de elevación solar (en el metadato), θ_{SZ} es el ángulo zenit local y $\rho_{\lambda'}$ es la reflectancia planetaria al techo de la atmósfera sin corrección atmosférica.

Existen, a su vez, relaciones para convertir la radiancia espectral en valores de temperatura (a partir de sensores que contienen bandas capaces de capturar información el espectro térmico), pero se aleja del foco del presente trabajo y de las calibraciones propiamente tal.

D. Ejemplo de simulación con PROSPECT

A continuación se utilizarán tres muestras de la base de datos “LOPEX93” para obtener sus medidas de reflectancia mediante simulación con PROSPECT. Las opciones serán los porotos de soya (*Glycine max L.*), lechuga (*Lactuca sativa L.*) y laurel (*Laurus nobilis L.*). Los parámetros necesarios para modelar en PROSPECT se pueden observar en la [Tabla D.1](#), mientras que algunas fotografías de las plantas se pueden observar en la [Figura D.1](#).

Tabla D.1: Ejemplo de porotos de soya (*Glycine max L.*), Lechuga (*Lactuca sativa L.*) y Laurel (*Laurus nobilis L.*) para modelar en PROSPECT en base a información de LOPEX93.

Fuente: Información obtenida de LOPEX93 para Porotos de soya, Lechuga y Laurel, muestras número #321, #24 y #68, respectivamente ([Hosgood et al., 1994](#)).

	N ^a	C _{a+b} ^b	C _{car} ^c	EWT ^d	LMA ^e
<i>Glycine max L.</i>	1,72	1,36	5,15	0,0080	0,0032
<i>Lactuca sativa L.</i>	2,04	27,23	6,16	0,0236	0,0020
<i>Laurus nobilis L.</i>	2,26	58,22	12,30	0,0141	0,0128

^aParámetro de la estructura de la hoja.

^bConcentración de clorofila a+b a nivel de hoja [$\mu\text{g cm}^{-2}$].

^cConcentración de carotenoides de la hoja [$\mu\text{g cm}^{-2}$].

^dEquivalent Water Thickness [g cm^{-2}]

^eMasa de la hoja por unidad de área (*Leaf mass per area*) [g cm^{-2}]



(a) *Glycine max L.*



(b) *Lactuca sativa L.*



(c) *Laurus nobilis L.*

Figura D.1: Fotografías de algunas muestras de LOPEX93, que se ejemplificaran para entender de mejor manera de que se trata tanto LOPEX93 como PROSPECT. (a) corresponde a Porotos de soya (nombre científico: *Glycine max L.*), (b) corresponde a Lechuga (nombre científico: *Lactuca sativa L.*) y (c) corresponde a Laurel (nombre científico: *Laurus nobilis L.*).

Fuente: Porotos de soya (*Glycine max L.* – [Planae.ca, 2015](#)); Lechuga (*Lactuca sativa L.* – [PROTA4U, 2015](#); Laurel (*Laurus nobilis L.* – [EcoAgricultura, 2015](#)).

Así, y por medio de la información entregada por PROSPECT (con ésta data se realizó la [Figura D.2](#)), es posible calcular diversos índices espectrales que se ubiquen entre el rango espectral comprendido entre los 400 y 2.500 nm.

Por otro lado, cabe destacar que la resolución espectral con la que PROSPECT simula la reflectancia es de 1 nm. De esta forma, es posible contar con un modelo de un espectro continuo simulado desde, como ya se dijo, los 400 hasta los 2.500 nm. A su vez, es interesante dar cuenta de la situación de los porotos de soya (*Glycine max L.*), en la [Figura D.2](#) se puede observar un comportamiento muy distinto al de las otras dos curvas. La primera porción del espectro analizado, entre los 400 y 750 nm, aproximadamente, es donde se identifican los pigmentos de la vegetación, así como su actividad fotosintética. Es decir, el contenido de clorofila, carotenoides, entre otros ([Chuvieco, 2010](#)). De esta

forma, en los parámetros de entrada que pide PROSPECT se encuentran la clorofila a y b (C_{a+b}), que puede adquirir valores entre 0 y 100 [$\mu\text{g}/\text{cm}^2$]. Así, es importante destacar que los valores de clorofila a+b (C_{a+b}) en el caso de los Porotos de soja (*Glycine max L.*) son bastante bajos en relación a la Lechuga y Laurel (ver [Tabla D.1](#)), lo que se puede asumir, a su vez, para el caso de los carotenoides (C_{car}).

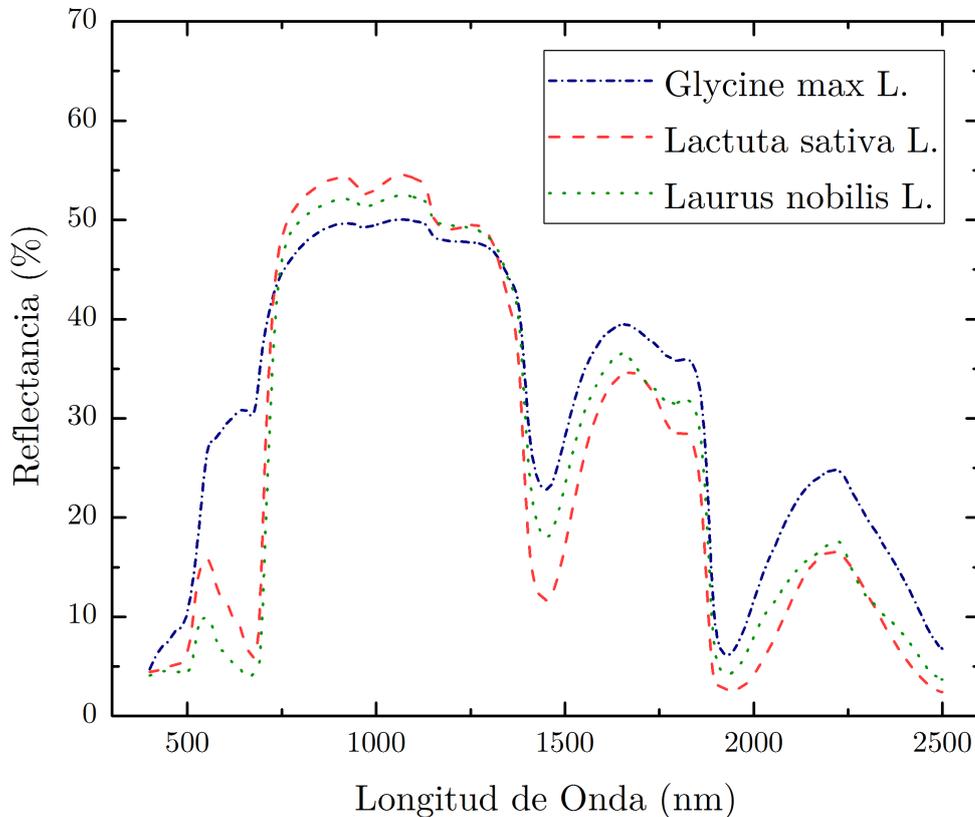


Figura D.2: Firma espectral de *Glycine max L.* (Porotos de soja), *Lactuca sativa L.* (Lechuga) y *Laurus nobilis L.* (Laurel) mediante data recolectada por LOPEX93 (muestra #321, #24 y #68, respectivamente) y estimada con PROSPECT.

Fuente: Elaboración propia por medio de información de LOPEX93 y PROSPECT.

E. Resumen de mapas de modelos/tipos de combustible

Tabla E.1: Resumen de los autores, fechas, técnicas, sensores y sistema de clasificación digital de mapas de modelos/tipos de combustible. Respecto a las técnicas: Clasificación Supervisada (S), no supervisada (NS), componentes puros (CP) y redes neuronales (RN). En cuanto a los sensores: MultiSpectral Sensor (MSS), Advanced very high resolution radiometer (AVHRR), Thematic Mapper (TM), Synthetic aperture radar (SAR), Thematic Mapper de satélites SPOT (TM-SPOT).

Autor	Fecha	Método de clasificación	Sensor	Sistema
Kourtz	1977	S, NS	MSS	Propio
Rabii	1979	NS	MSS	Propio
Shasby	1981	Mixta	MSS	NFDRS
Consentino y Estes	1981	NS	MSS	Propio
Benson et al.,	1982	NS	MSS	NFFL
Salazar	1982	NS	MSS	NFDRS NFFL
Dixon	1984	S	MSS	FBP
Burgan y Shasby	1984	NS	MSS	NFDRS
McKinley et al.,	1985	NS	AVHRR	NFFL
Werth et al.,	1985	NS	AVHRR	NFFL
Agee y Pickford	1985	NS	MSS	NFDRS
Miller y Johnson	1985	NS	AVHRR	NFDRS
Miller et al.,	1986	NS	AVHRR	NFDRS
Root et al.,	1986	NS	MSS	NFFL
Ow et al.,	1993	S	MSS	FBP
Wilson et al.,	1994	S	MSS	FBP
Campbell	1995	S, NS	TM	NFFL
Salas y Chuvieco	1995	S, NS, Mixta	TM	ICONA
Van Wagendonk	1997	NS	TM	Propio
Roberts et al.,	1997	CP	AVIRIS	NFFL
Kyun	1997	S	SAR-TM	NFFL
Vasconcelos et al.,	1998	RN	TM	NFFL
Castro y Chuvieco	1998	S	TM-SPOT	Propio
Burgan et al.,	1998	NS	AVHRR	NFDRS
Miller y Yool	1999	S	TM	Propio
Vázquez y Denore	1999	S, NS	TM-SPOT	Propio
Van Wagendonk y Root	2002	CP	TM	Propio
Riaño et al.,	2002	S	TM	Prometheus

Fuente: Tabla obtenida de Cocero *et al.* (2004), página 41.

F. Características generales de las agujas y conos de pino

	Pine Needles	Pine Cones
Moisture (wt. %)	12	8,9
Analysis on dry basis		
• C (wt. %)	50,4	54,2
• H (wt. %)	6,5	6,8
• N (wt. %)	0,8	0,3
• S (wt. %)	0,01	-
• Ash Content (wt. %)	4,5	0,8
• O % by difference (wt. %)	37,9	38,7
• Cl (wt. %)	0,22	0,17
• Net calorific value [kJ/kg]	20,138	18,782
• Ethanol extracts	18,2	7,3
• Hemicellulose	17,7	21,7
• Cellulose	38,7	39,3
• Lignin	20,1	30,9

Tabla F.1: Características generales de agujas y conos de pino.
Fuente: Obtenida de Font *et al.* (2009).

G. Diferencias en el parámetro de estructura interna

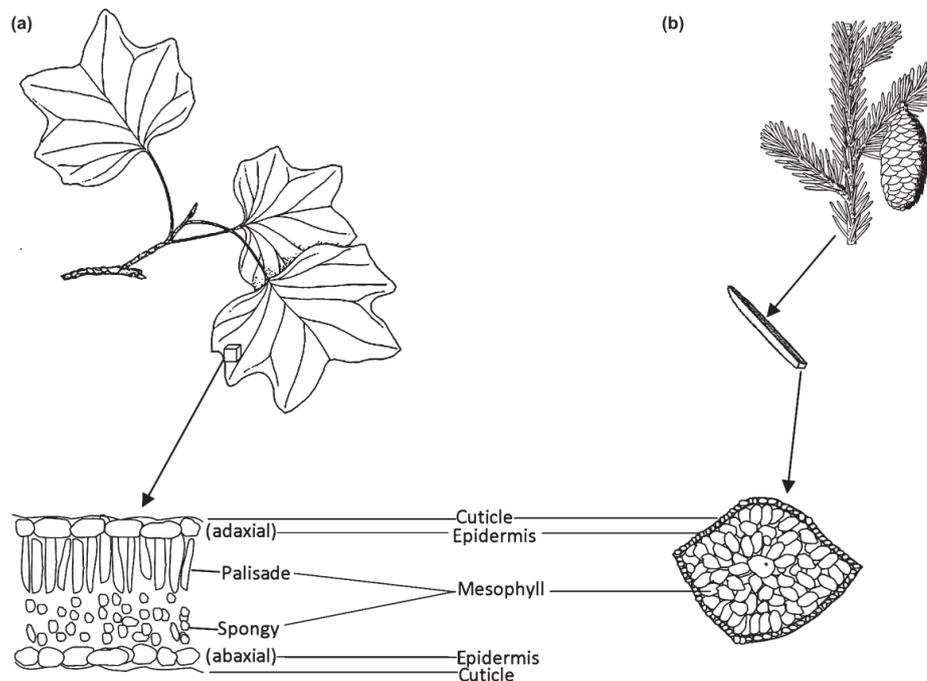


Figura G.1: Diferencias en los parámetros de estructura interna (N) para PROSPECT.
Fuente: Obtenida de Ollinger (2011).

H. Metodología para estimar el área de una aguja de pino con programa ImageJ

A continuación se presentarán los pasos a seguir para determinar el área de una hoja con el software ImageJ (que se puede descargar de libre acceso aquí: <https://imagej.nih.gov/ij/download.html>).

El único *input* al programa viene siendo la fotografía tomada a las muestras sobre una hoja blanca (de impresora) con una regla en donde se puedan observar los intervalos de medición. Luego, el procedimiento consiste en:

1. Abrir el programa ImageJ
2. Abrir la imagen a analizar.
3. Seleccionar la lupa e ir hasta donde se pueda discriminar en las medidas de *cm* de la regla en la fotografía.
4. Con la herramienta *straight* se deben medir unos 2 *cm* a partir de la regla manteniendo el botón izquierdo apretado del mouse.
5. Luego, ir a *Analyze* → *Set Scale* y cambiar el “*known distance*” al valor seleccionado en la distancia de la regla. Luego seleccionar “*Unit of length*”: *cm* y hacer click en el cuadrado “*Global*”.
6. Ir a *Image* → *Adjust* → *Threshold* e ir moviendo ajustes hasta que las hojas queden de color rojo. (Observación: si se cuenta con un iPhone 6, éste tiene una resolución de 8 Bits, por lo que bastaría ir a *Image* → *Type* y poner resolución radiométrica (Bits) y luego solo habrá que poner la opción de *Threshold* sin tener que realizar cambios manuales).
7. Luego de que las hojas queden de color rojo y el fondo blanco, ir a: *Analyze* → *Tools* → *ROI Manager* y:
 - a) Seleccionar la varita (*Wand*) en las opciones de ImageJ (abajo de donde dice *Analyze* y seleccionar una hoja.)
 - b) Luego de seleccionada una hoja, hacer click en “*Add*”.
 - c) Repetir los pasos anteriores, se recomienda recordar el orden en caso de ser necesario (dado que ImageJ solo irá poniendo en la tabla los resultados en el orden que se le dio).
 - d) Al finalizar con todas las hojas, apretar “*Measure*” en las opciones de *ROI Manager*, en donde se obtendrá un breve análisis estadístico que incluye las áreas, la media, la mínima y máxima, etc.

I. Imágenes satelitales correspondientes a la experiencia 2 y 3

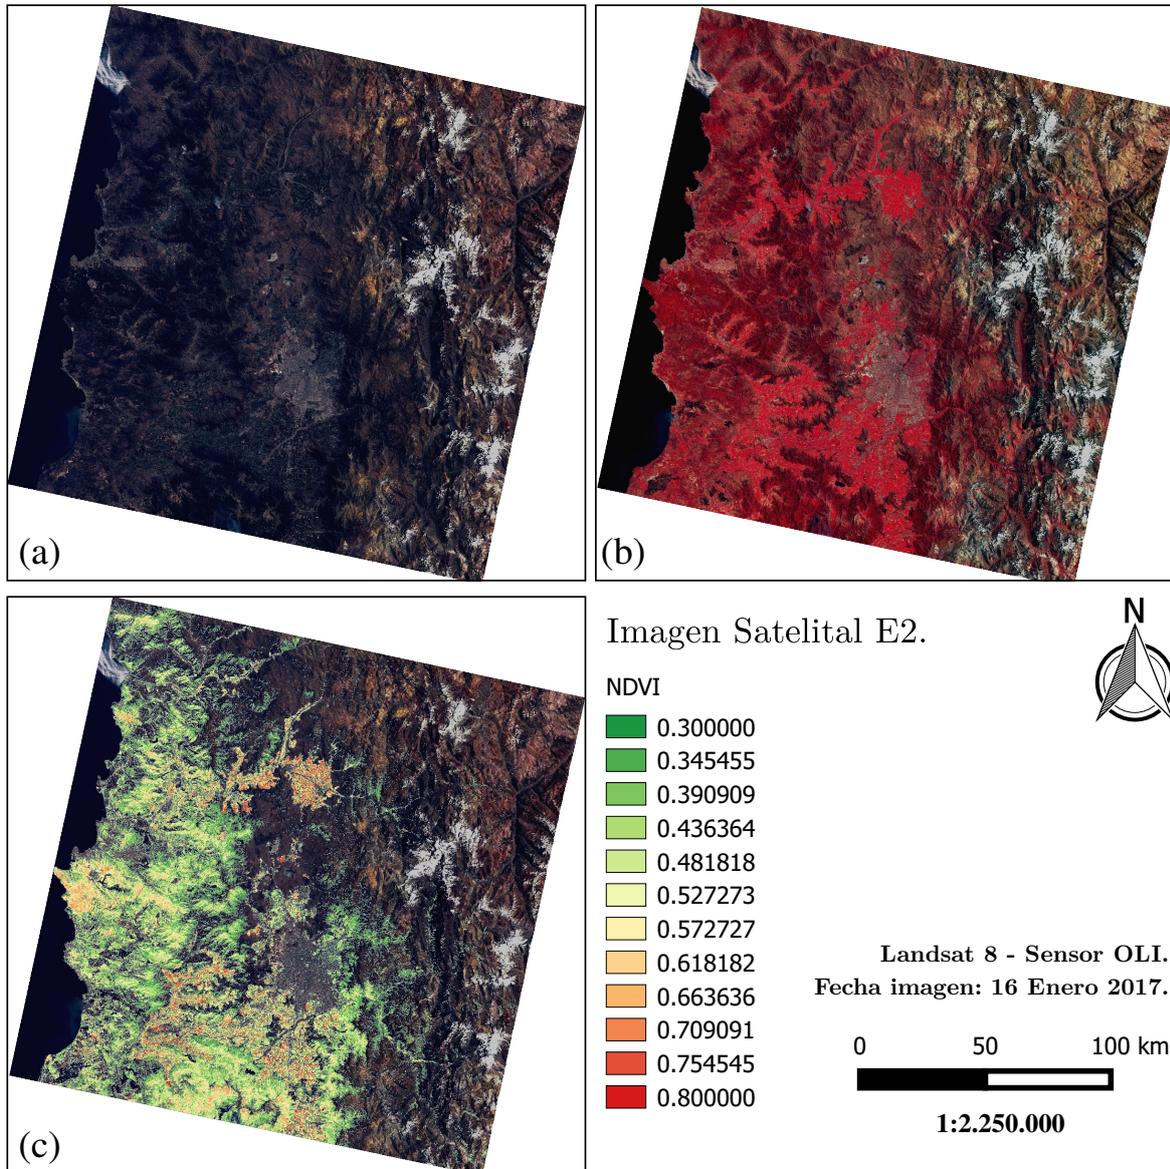


Figura I.1: Imagen satelital correspondiente a la experiencia 2. (a) corresponde a la imagen en color real (RGB), (b) corresponde a la imagen en falso color (infrarrojo) y (c) presenta el NDVI para la imagen. Valores más cercanos a 1 implican vegetación más vigorosa.

Fuente: Elaboración propia.

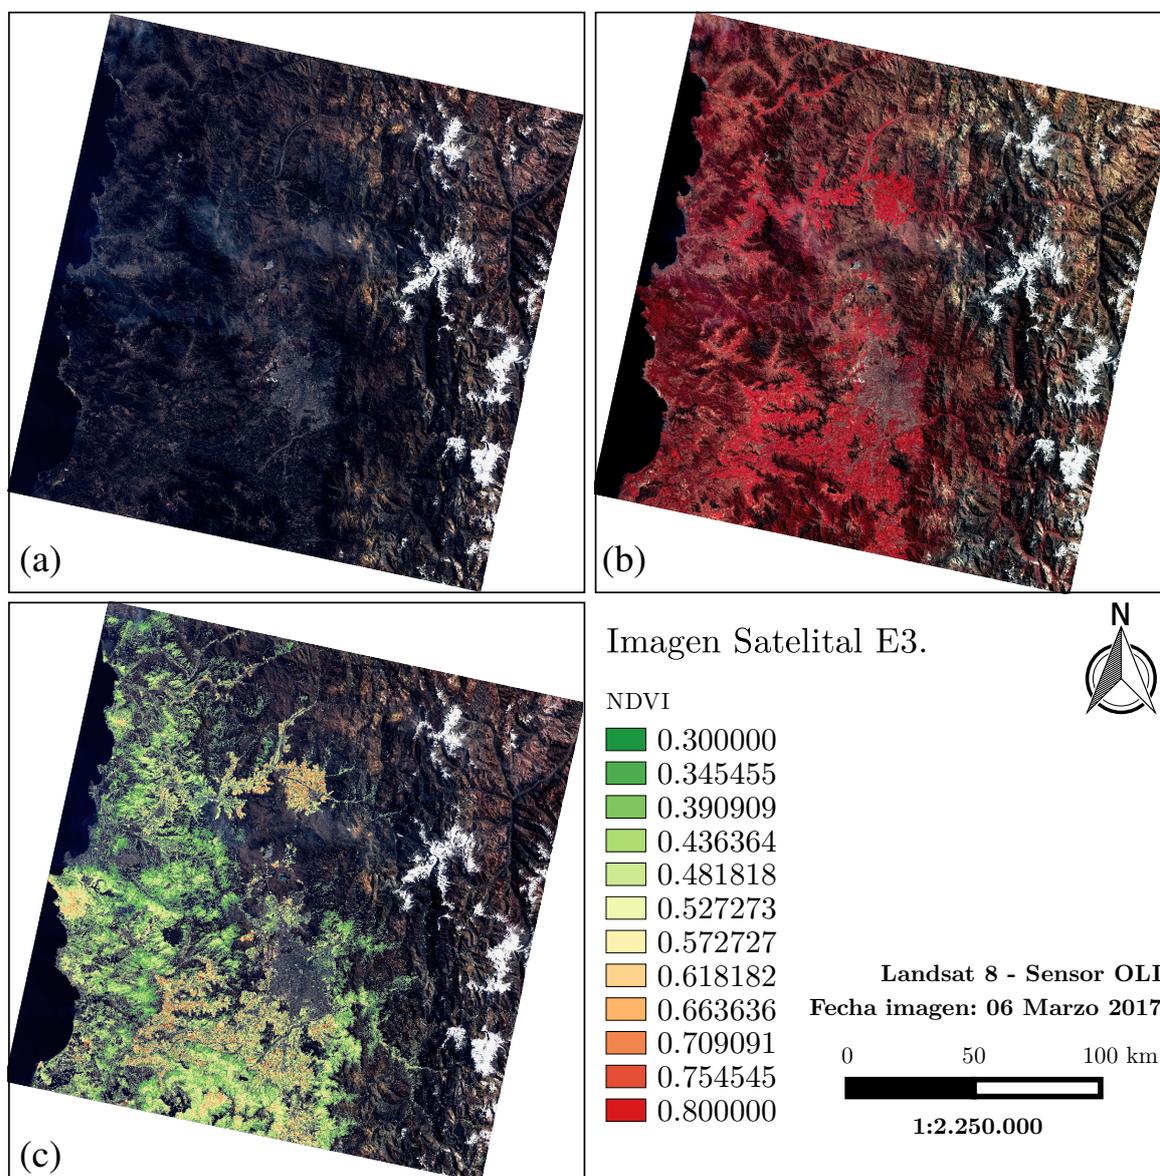


Figura I.2: Imagen satelital correspondiente a la experiencia 3. (a) corresponde a la imagen en color real (RGB), (b) corresponde a la imagen en falso color (infrarrojo) y (c) presenta el NDVI para la imagen. Valores más cercanos a 1 implican vegetación más vigorosa.

Fuente: Elaboración propia.

J. Variación entre índices espectrales a nivel satelital y a nivel hiperespectral

En la [Figura J.1](#) se pueden apreciar las variaciones, a partir de diagramas de cajas, de los índices espectrales obtenido a nivel hiperespectral (con la simulación en PROSPECT) y a nivel satelital (con matemática de bandas a las imágenes satelitales). Como se dijo en la [Sección 5.4](#), se aprecia, en general, una subestimación por parte de los datos a nivel satelital, donde también se puede destacar la gran variación que tuvo el índice EVI, que si bien disminuyó su rango de valores a nivel satelital, ahora dicho rango varía en otros valores absolutamente distintos que aquellos a nivel espectral. Sin embargo, lo anterior se debe a que el índice EVI fue elaborado para ser determinado a nivel satelital y no por medio de espectrometría. La obtención de dicho índice se adquiere a partir de una metodología que consiste en obtener la reflectancia media del rango de valores a determinada banda del sensor OLI para estimar el índice. Por ejemplo, el índice EVI utiliza, entre otras, la banda 5 del sensor OLI, que varía entre los 845 – 885 nm, por lo que el punto medio de dicha banda equivale a 865 nm. Por ende, para el valor de la banda 5 se utilizó el valor de reflectancia ubicado a los 865 nm.

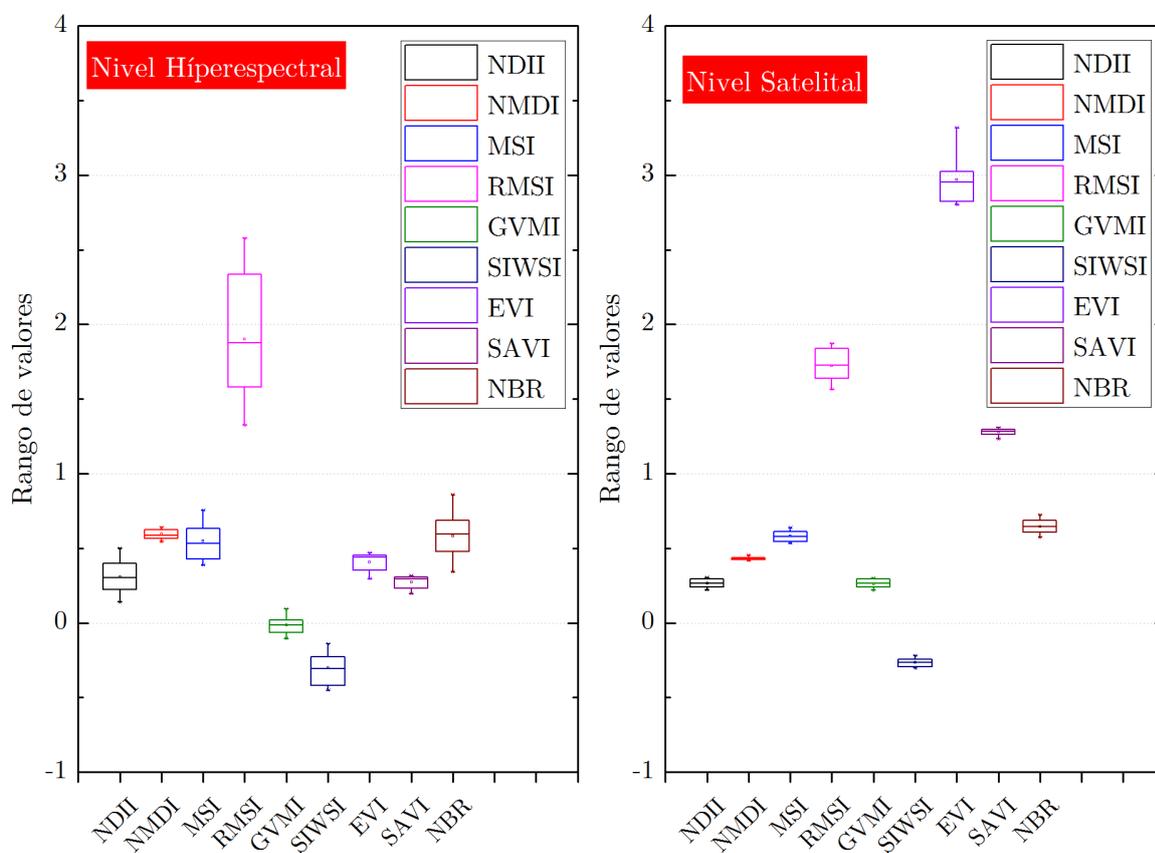


Figura J.1: Variación entre índices a nivel satelital y a nivel hiperespectral.

Fuente: Elaboración propia.

