



**UNIVERSIDAD DE CHILE**  
**FACULTAD DE CIENCIAS AGRONÓMICAS**  
**ESCUELA DE POSTGRADO**

**EVALUACION DEL RENDIMIENTO EN GENOTIPOS DE TRIGO HARINERO (*Triticum aestivum*) USANDO LONGITUDES DE ONDA CORRESPONDIENTES AL ESPECTRO VISIBLE, ROJO CERCANO Y ROJO MEDIO BAJO TRES CONDICIONES HÍDRICAS.**

Tesis para optar al Grado de Magister en Ciencias Agropecuarias,  
Mención Producción de Cultivos

**F.JAVIER HERNANDEZ VASQUEZ**

Directores de Tesis  
MAURICIO GALLEGUILLOS TORRES  
PAOLA SILVA CANDIA

Profesores consejeros  
JAIME HERNANDEZ  
LUIS MORALES

SANTIAGO - CHILE  
2014

**UNIVERSIDAD DE CHILE**  
**FACULTAD DE CIENCIAS AGRONÓMICAS**  
**ESCUELA DE POSTGRADO**

EVALUACION DEL RENDIMIENTO EN GENOTIPOS DE TRIGO  
HARINERO (*Triticum aestivum*) USANDO LONGITUDES DE ONDA  
CORRESPONDIENTES AL ESPECTRO VISIBLE, ROJO CERCANO Y  
ROJO MEDIO BAJO TRES CONDICIONES HÍDRICAS.

Tesis presentada como parte de los requisitos para optar al Grado de Magíster en  
Ciencias Agropecuarias, Mención Producción de Cultivos.

**F.JAVIER HERNANDEZ VASQUEZ**

Calificaciones

DIRECTOR DE TESIS

Mauricio Galleguillos T  
Ingeniero Agrónomo, M.S., Ph. D.

Aprobado

Paola Silva C  
Ingeniero Agrónomo, MS, Dra

Aprobado

PROFESORES CONSEJEROS

Luis Morales S  
Profesor de Ciencias Naturales y Física, MS, Dr.

Aprobado

Jaime Hernández P  
Ingeniero Forestal, MS, Dr.

Aprobado

Santiago, Chile  
2014

# ÍNDICE

## Índice de contenidos

### Capítulo I: Monografía

I. Revisión bibliográfica.....	1
1. Mejoramiento genético del trigo.....	1
1.1. Caracteres Indirectos. ....	1
2. Reflectancia en plantas. ....	2
2.1. Evaluación del estrés hídrico mediante reflectancia.....	3
2.2. Índices de reflectancia Espectral.....	3
2.3. Modelos de regresión multivariados.....	4
3. Literatura Citada.....	6

### Capitulo II

II. Evaluación del rendimiento en genotipos de trigo harinero ( <i>Triticum aestivum</i> ) usando longitudes de onda correspondientes al espectro visible, rojo cercano y rojo medio bajo tres condiciones hídricas.....	10
1. Resumen.....	10
2. Abstract.....	11
3. Introducción.....	12
4. Hipótesis. ....	13
5. Objetivos.....	13
5.1.    Objetivo General.....	13
5.2.    Objetivos Específicos.....	13

6.	Materiales y Métodos.....	15
6.1.	Sitio de estudio.....	15
6.2.	Ensayos.....	15
6.3.	Tratamientos.....	15
6.4.	Diseño Experimental.....	16
6.5.	Manejo del cultivo.....	16
6.6.	Mediciones.....	16
6.7.	Genotipos contrastantes.....	17
6.8.	Índices de reflectancia Espectral (IRE's).....	17
6.9.	Generación modelo predictivo.....	17
6.10.	Análisis estadístico.....	19
7.	Resultados.....	20
7.1.	Rendimiento de los genotipos en los diferentes ambientes.....	20
7.2.	Firma espectral y su relación con el rendimiento.....	20
7.3.	Características de la firma espectral asociadas al rendimiento.....	21
7.4.	Modelo multivariado y longitudes de mayor peso relativo.....	23
7.5.	Utilización de IREs para estimación de rendimiento.....	24
7.6.	Construcción de modelos y su desempeño en la calibración.....	25
8.	Discusión.....	28
8.1.	Reflectancia de la canopia en condiciones contrastantes y su relación con el rendimiento. ....	28
8.2.	Reflectancia en hojas asociados a los coeficientes de los modelos.....	28

8.3.	IRes v/s modelos multivariados para la estimación del rendimiento.....	29
8.4.	Modelos individuales para la selección por rendimiento en ambientes contrastantes. ....	31
9.	Conclusiones.....	32
10.	Bibliografía. ....	33

## Índice de Cuadros

Cuadro 1. Características agroclimáticas de los sitios de ensayo .....	15
Cuadro 2. Parámetros principales de los rendimientos en los diferentes ambientes.....	20
Cuadro 3. Coeficientes de correlación entre IREs y rendimiento para los ambientes.....	25
Cuadro 4. Estadísticos más importantes de los modelos multivariados para estimar rendimientos basados en la firma espectral.....	25
Cuadro 5. Coeficientes de correlación de modelos aplicados en diferentes ambientes.....	27

## Índice de Figuras

Figura 1. Procesos utilizados para la obtención del lambda óptimo del modelo de regresión ridge.....	19
Figura 2. Coeficiente de correlación de Pearson (r) entre rendimiento y longitudes de onda de la firma espectral para cada ambiente y estado fenológico.....	21
Figura 3. Reflectancia estandarizada (SNV) de los 15 genotipos de mayor y menor rendimiento.....	22
Figura 4. Peso Relativo de Coeficientes de Regresión de para cada una de las longitudes de onda. ....	24
Figura 5. Validación del rendimiento observado ( $\text{kg ha}^{-1}$ ) utilizando los coeficientes de los modelos combinados.....	26

## **CAPÍTULO I: MONOGRAFÍA**

### **EVALUACION DEL RENDIMIENTO EN GENOTIPOS DE TRIGO HARINERO (*Triticum aestivum*) USANDO LONGITUDES DE ONDA CORRESPONDIENTES AL ESPECTRO VISIBLE, ROJO CERCANO Y ROJO MEDIO BAJO TRES CONDICIONES HÍDRICAS.**

#### **Revisión Bibliográfica**

##### **Mejoramiento genético del trigo**

Durante el siglo pasado, el mejoramiento genético ha hecho uso en forma extensiva del método clásico de evaluación y selección de genotipos, el cual toma como mayor criterio de selección el rendimiento por se (Loss y Siddique, 1994). Habitualmente, las estrategias de mejoramiento consisten en la comparación de genotipos que tengan altos rendimientos, lo cual conlleva una evaluación dentro y entre un gran número de poblaciones segregantes derivadas de diversos cruzamientos (Ball y Konzak, 1993). Sin embargo, este tipo de ensayos, usualmente requieren numerosas repeticiones replicadas durante varios años, lo que implica costos operativos elevados así como también un consumo de tiempo alto asociado a sus mediciones (Royo *et al.*, 2003). Estos acercamientos empíricos en base al rendimiento han sido modestos en ambientes mediterráneos de secano, debido principalmente a que el factor más limitante al rendimiento, es el estrés hídrico, el cual afecta la última parte de desarrollo del cultivo (Acevedo *et al.*, 1999; Richards, 1982). Además, se ha demostrado que la selección por rendimiento tiene baja heredabilidad y alta interacción genotipo medio ambiente (Araus *et al.*, 2002; Blum, 1988), por lo tanto, métodos que logren estimar el rendimiento en estados iniciales o intermedios, serán de gran utilidad para el mejoramiento en condiciones de estrés hídrico. Considerando estas evidencias, la generación de una metodología eficiente para evaluar el rendimiento entre diferentes genotipos antes de cosecha que optimice los costos y el tiempo requerido para la selección es de gran relevancia para los programas de mejoramiento (Araus *et al.*, 2001).

##### **Caracteres indirectos**

En los últimos años, han sido varios los métodos basados en caracteres fisiológicos, morfológicos y bioquímicos desarrollados para la selección y discriminación de genotipos, habiendo sido escasamente adoptados (Araus, 1996; Jackson, 2001). Esto se puede deber en parte, al poco o escaso entendimiento de los procesos fisiológicos que están directamente vinculados en la determinación de rendimiento, en adición a la ausencia de métodos apropiados para evaluarlos de una forma rápida y oportuna (Blum, 1988; Richards, 1996).

Un ejemplo de estos es la discriminación del isótopo carbono 13 ( $\Delta^{13}\text{C}$ ), el cual ha tenido éxito en la selección de genotipos bajo condiciones de estrés hídrico (Condon *et al.*, 2002; Rebetzke *et al.*, 2002). Sin embargo, la determinación de  $\Delta^{13}\text{C}$  es un proceso de alto costo y muy lento, lo que lo hace un método difícil de implementar a gran escala. Otros instrumentos han sido desarrollados para medir indirectamente ciertos caracteres fisiológicos como los clorofilómetros y porómetros. Sin embargo, el uso de estos instrumentos para la predicción de rendimiento para el caso del maíz, hasta ahora no ha sido del todo exitosa, debido a la baja heredabilidad por presentar una baja correlación con el rendimiento (Monneveux *et al.*, 2008). Para que los caracteres indirectos sean utilizados, deben integrar tres procesos mayores, que en su conjunto muestren una asociación entre el rendimiento y la canopia de la planta (Aparicio *et al.*, 2000; Araus, 1996). El primero tiene relación con la cantidad de radiación que es capaz de ser interceptada por la canopia. El segundo, será la capacidad de la canopia en convertir esta radiación interceptada en energía química potencial o eficiencia fotosintética del cultivo y en tercer lugar está el índice de cosecha, el cual es la proporción de grano en relación a la cantidad total de materia seca producida (Aparicio *et al.*, 2000). En este sentido, se ha visto, que mediciones de reflectancia de la canopia y de la hoja cumplen con estas condiciones al estimar simultáneamente caracteres como el área verde de la canopia y la eficiencia en el uso de la radiación, los cuales y le dan al cultivo la habilidad para interceptar la radiación incidente y realizar fotosíntesis (Araus, 1996; Peñuelas y Filella, 1998).

## **Reflectancia en plantas**

Las hojas de las plantas superiores son primeramente órganos foto-sintetizadores, siendo los cloroplastos, el lugar donde ocurre la fotosíntesis. En los cloroplastos se encuentran pigmentos tales como la clorofila, carotenoides y xantofilas, siendo el primero de ellos, el que se encuentra en mayor cantidad y el que realiza la mayor parte de la fotosíntesis. La radiación que llega hasta las hojas, interactúa con su estructura y contenido de pigmentos. De este modo, la luz que entra a las hojas, puede ser absorbida, reflejada o transmitida por la superficie de las hojas (Gates *et al.*, 1965).

Los sensores remotos detectan la energía electromagnética que es reflejada o emitida desde complejos ensamblajes biológicos, geológicos e hidrológicos desde la superficie de la tierra. Los datos obtenidos desde estas mediciones pueden ser interpretados correctamente solo si se conocen las bases de las interacciones de la energía en la tierra que dan cuenta de las variaciones en la cantidad y calidad de la radiación recolectada por los sensores remotos (Knipling, 1970).

Debido a que en las plantas la reflectancia responde a variables dependientes de la canopia asociadas al rendimiento tales como índice de área foliar, índice de verdor y materia seca (Aparicio *et al.*, 2002; Aparicio *et al.*, 2000) es posible utilizar las mediciones para predecir el rendimiento (Aparicio *et al.*, 2000; Araus, 1996). Por otra parte, debido a que la reflectancia entrega información sobre el contenido de clorofila (Sims y Gamon, 2002), biomasa aérea (Liu *et al.*, 2010) y contenido de agua en la planta (Peñuelas *et al.*, 1993a) es también posible realizar evaluaciones que pueden ser usadas para asistir en el diagnóstico de diversas condiciones de estrés en la planta (Peñuelas y Inoue, 1999). De

este modo, las mediciones de reflectancia representan una variable potencialmente útil para estimar en forma rápida, fácil y no destructiva caracteres estructurales y fotosintéticos de la canopia asociados al rendimiento en un determinado cultivo (Araus, 1996; Araus *et al.*, 2002).

### **Evaluación del estrés hídrico mediante reflectancia**

La evaluación del estado hídrico de la canopia a partir de datos provenientes de sensores remotos, ha sido de gran interés para la agronomía y ecología. El estado hídrico de una planta, definido como el contenido de agua de la hoja o el contenido de agua de la canopia, puede ser determinado a partir de la luz reflejada por las hojas (Knipling, 1970; Peñuelas *et al.*, 1997b; Serrano *et al.*, 2000b). Esta evaluación se puede realizar considerando longitudes de onda que son absorbidas por el agua contenida en la estructura del follaje (Seelig *et al.*, 2008). Sin embargo, aun cuando se han obtenido correlaciones entre diferentes índices espectrales y el contenido de agua en los tejidos, existen muchos factores que influyen en esta asociación (Peñuelas y Filella, 1998; Seelig *et al.*, 2008), tales como la vegetación, factores ambientales, variabilidad atmosférica, lumínica, ángulo de la medición de la reflectancia y heterogeneidad de la superficie (Knipling, 1970; Peñuelas *et al.*, 1993a). No obstante, es posible identificar que la absorción de radiación en las regiones del espectro visible es principalmente causada por los pigmentos de las hojas mientras que la absorción en las regiones del infrarojo cercano (NIR) e infrarojo medio (SWIR) es debido principalmente por el agua, donde al menos cinco longitudes de onda centradas entre las 970 y 2500 nm dan la posibilidad de evaluar el contenido del agua en las hojas en forma remota (Knipling, 1970; Kou *et al.*, 1993).

### **Índices de reflectancia o IRES**

Las estimaciones de caracteres fisiológicos (índice de área foliar, índice de verdor, materia seca, etc) asociados al rendimiento pueden ser logradas mediante el uso de índices asociados a diferentes longitudes de onda, llamados índices de reflectancia espectral (IREs), los cuales están basados sobre simples operaciones o relaciones entre la reflectancia de la canopia a determinadas longitudes de onda (Aparicio *et al.*, 2000; Araus, 1996; Peñuelas y Filella, 1998). Estos IRES han sido establecidos para estimar tanto caracteres fisiológicos de la planta como para predecir rendimientos mediante mediciones periódicas de reflectancia en la canopia durante todo el periodo de desarrollo de la planta (Aparicio *et al.*, 2002; Araus *et al.*, 2002; Royo *et al.*, 2003). Varios son los índices desarrollados para la estimación de caracteres fisiológicos, encontrándose dentro de los más utilizados el índice de vegetación de diferencias normalizado [NDVI;  $(R900 - R680) / (R900 + R680)$ ] (Araus *et al.*, 2002; Peñuelas y Filella, 1998) y el de radio simple [SR;  $(R900 / R680)$ ] (Aparicio *et al.*, 2000; Serrano *et al.*, 2000b). Ambos índices han sido correlacionados positivamente (tanto en base logarítmica como lineal) con la masa seca del cultivo (MS), índices de área foliar (IAF), índice de área verde (IAV) y la capacidad de fotosíntesis potencial (Aparicio *et al.*, 2000; Araus *et al.*, 2002; Peñuelas y Filella, 1998).

Sin embargo, debido a que los resultados obtenidos a partir del uso de estos índices reducen significativamente la amplia información contenida en otras áreas del espectro, estos índices generan modelos de estimación que son inestables y algunas veces inviables, especialmente en aquellos estudios donde la variabilidad atmosférica, iluminación solar, ángulo de medición, heterogeneidad de superficie, topografía y vegetación son heterogéneas (Cho *et al.*, 2007; Knipling, 1970). Además, la eficiencia con la cual este tipo de índices discriminan genotipos y especies varían significativamente entre plantas y ecosistemas (Gamon *et al.*, 1995). Se han reportado varios estudios donde han aparecido inconsistencias o diferencias no significativas en la reflectancia entre plantas estresadas y no estresadas (Seelig *et al.*, 2008). Estas inconsistencias son aparentemente gobernadas por efectos independientes a las longitudes de onda que actúan sobre la deshidratación de las hojas, donde se encuentran cambios en la estructura interna de la hoja tales como tamaño de la célula, forma celular, estructura y turgor dando por resultado diferencias en la cantidad y tamaño de la superficie reflectiva, la que puede contribuir a la dispersión de la radiación desde grandes partículas desde el interior de hoja (Carter, 1991). Debido a que estos estudios muestran además de una correlación fenotípica débil y una dependencia en el rango de variación del material evaluado (Royo *et al.*, 2003), las longitudes de onda usadas para generar los índices mencionados pueden variar de acuerdo con el estado de desarrollo y condiciones ambientales (Weber *et al.*, 2012). Como una forma de solucionar estos problemas, se ha propuesto utilizar la totalidad del espectro de radiación de onda corta o reflectancia espectral mediante la generación de modelos de regresión multivariados, los cuales realizarían una mejor predicción al rendimiento que los modelos generados a partir de los IREs (Addink *et al.*, 2007; Ferrio *et al.*, 2005; Weber *et al.*, 2012).

### **Modelos de regresión multivariados**

Dada la alta variación de los IREs en la predicción del rendimiento, por factores vinculados a la anatomía, espesor de la hoja y estructura de la canopia, Filella *et al.* (1995) propusieron integrar diferentes IREs, obteniéndose correlaciones significativas entre una combinación de índices y la concentración de clorofila.

Por otro lado, cuando se realizan regresiones lineares basadas en mínimos cuadrados ordinarios, se observa problemas de predicción en los modelos. Esto se debe a que datos provenientes de sensores remotos tienen normalmente una alta dimensionalidad, donde el número de variables predictoras (longitudes) es más grande que el número de observaciones (mediciones) y por lo tanto se generan relaciones erróneas entre las variables predictoras y de respuestas, sumado, a la alta posibilidad en la existencia de una multicolinealidad entre las variables predictoras (Lazaridis *et al.*, 2010).

Es por esto que técnicas de regresiones estándar o basadas en mínimos cuadrados ordinarios, otorgan resultados poco significativos, siendo por lo tanto necesario evaluar técnicas de regresión basadas en la penalización de los parámetros de la regresión, los cuales, generan una predicción más robusta en presencia de una alta dimensionalidad y multicolinealidad de las variables (Hastie *et al.*, 2005). De este modo, modelos de regresión lineal multivariada, basados a partir de la información de reflectancia de alta resolución espectral, son a menudo utilizados como un método alternativo para derivar la

relación entre las múltiples variables explicatorias y una variable respuesta (Cai *et al.*, 2009). Sin embargo, debido a que las bases fisiológicas y bioquímicas entre la relación de la canopia y la reflectancia son extremadamente complejas y de difícil interpretación, se deben usar métodos empíricos para la generación de modelos estadísticos multivariados para predecir el rendimiento (Ferrio *et al.*, 2005).

Uno de estos modelos multivariados, es la regresión ridge, la cual fue introducida por Tikhonov (1943) y luego fue popularizada por Hoerl y Kennard (1970a); Hoerl y Kennard (1970b). Este tipo de regresión lineal multivariada, incluye una contracción de los coeficientes de la regresión del modelo multivariado, reduciéndolos en igual magnitud (Lazaridis *et al.*, 2010). En otras palabras, la regresión ridge reduce la suma de cuadrados de los parámetros utilizados en la regresión, minimizando con ello la suma de cuadrados del error. Los coeficientes de la regresión están dados por:

$$\hat{\beta}^{\text{ridge}} = \underset{\beta}{\operatorname{argmin}} \left\{ \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\}$$

donde lamda ( $\lambda$ ) es el grado de contracción de la regresión, N es el número de observaciones,  $y_i$  es la variable dependiente,  $x_{ij}$  es la variable independiente,  $\beta_0$  es intercepto,  $\beta_j$  es el coeficiente de la regresión,  $\operatorname{argmin} \beta$  es el argumento mínimo de  $\beta$  y  $p$  son el número de variables independientes.

Existen dos formas para calcular el valor de lambda:

- 1-Mediante el uso de fórmulas empíricas (Hoerl y Kennard, 1970a; Hoerl y Kennard, 1970b)
- 2- Mediante el uso de datos independientes o validación cruzada, que minimicen el error de la predicción (Hastie *et al.*, 2005; Lazaridis *et al.*, 2010).

De este modo, la regresión ridge resulta en una menor varianza para los estimadores de los parámetros y aumenta la asertividad en comparación a métodos que utilicen los mínimos cuadrados ordinarios, generando modelos que pueden predecir en forma más eficiente, a partir de una gran cantidad de información (Miller, 1984).

## LITERATURA CITADA

- Acevedo, E. H.; P. Silva; H. Silva y B. Solar. 1999. Wheat: ecology and physiology of yield determination: Wheat production in Mediterranean environments. Food Products Press. New York. 295-331.
- Addink, E. A.; S. M. De Jong y E. J. Pebesma. 2007. The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery. *Photogrammetric Engineering and Remote Sensing*, 73(8): 905.
- Aparicio, N.; D. Villegas; J. L. Araus; J. Casadesús y C. Royo. 2002. Relationship between growth traits and spectral vegetation indices in durum wheat. *Crop Science*, 42(5): 1547-1555.
- Aparicio, N.; D. Villegas; J. Casadesús; J. L. Araus y C. Royo. 2000. Spectral vegetation indices as nondestructive tools for determining durum wheat yield. *Agronomy Journal*, 92(1): 83-91.
- Araus, J. L. 1996. Increasing yield potential in Wheat: Breaking the barriers.: Integrative physiological criteria associated with yield potential. (Eds.) Reynolds, M. P., S. Rajaram y A. McNab. CIMMYT. Mexico, D.F. 150-167.
- Araus, J. L.; J. Casadesús y J. Bort. 2001. Application of physiology in wheat breeding: Recent tools for the screening of physiological traits determining yield. (Eds.) Reynolds, M. P., J. I. Ortiz-Monasterio y A. McNab. CIMMYT. Mexico, D.F. 59-77.
- Araus, J. L.; G. A. Slafer; M. P. Reynolds y C. Royo. 2002. Plant breeding and drought in C3 cereals: what should we breed for? *Annals of Botany*, 89(7): 925-940.
- Ball, S. T. y C. F. Konzak. 1993. Relationship between grain yield and remotely-sensed data in wheat breeding experiments. *Plant Breeding*, 110(4): 277-282.
- Blum, A. 1988. Plant breeding for stress environments. Ed CRC Press. Boca Raton, Florida
- Cai, T.; C. Ju y X. Yang. 2009. Comparison of ridge regression and partial least squares regression for estimating above-ground biomass with Landsat images and terrain data in Mu US Sandy Land, China. *Arid Land Research and Management*, 23(3): 248-261.
- Carter, G. A. 1991. Primary and secondary effects of water content on the spectral reflectance of leaves. *American Journal of Botany*: 916-924.
- Cho, M. A.; A. Skidmore; F. Corsi; S. E. Van Wieren y I. Sobhan. 2007. Estimation of green grass/herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression. *International Journal of Applied Earth Observation and Geoinformation*, 9(4): 414-424.

- Condon, A. G.; R. A. Richards; G. J. Rebetzke y G. D. Farquhar. 2002. Improving intrinsic water-use efficiency and crop yield presented at the 1999 CSSA Symposium on water use efficiency, organized by Div. C-2 chair, Dr. Tom Gerik. *Crop Science*, 42(1): 122-131.
- Ferrio, J. P.; D. Villegas; J. Zarco; N. Aparicio; J. L. Araus y C. Royo. 2005. Assessment of durum wheat yield using visible and near-infrared reflectance spectra of canopies. *Field Crops Research*, 94(2-3): 126-148.
- Filella, I.; L. Serrano; J. Serra y J. Peñuelas. 1995. Evaluating wheat nitrogen status with canopy reflectance indices and discriminant analysis. *Crop Science*, 35(5): 1400-1405.
- Gamon, J. A.; C. B. Field; M. L. Goulden; K. L. Griffin; A. E. Hartley; G. Joel. et al. 1995. Relationships between NDVI, canopy structure and photosynthesis in three californian vegetation types. *Ecological Applications*, 5(1): 28-41.
- Gates, D. M.; H. J. Keegan; J. C. Schleter y V. R. Weidner. 1965. Spectral properties of plants. *Applied Optics*, 4(1): 11-20.
- Hastie, T.; R. Tibshirani; J. Friedman y J. Franklin. 2005. The elements of statistical learning: data mining, inference and prediction. *The Mathematical Intelligencer*, 27(2): 83-85.
- Hoerl, A. E. y R. W. Kennard. 1970a. Ridge regression: applications to nonorthogonal problems. *Technometrics*, 12(1): 69-82.
- Hoerl, A. E. y R. W. Kennard. 1970b. Ridge regression: biased estimation for nonorthogonal problems. *Technometrics*, 12(1): 55-67.
- Jackson, P. A. 2001. Application of physiology in wheat breeding: Directions for physiological research in breeding: Issues from a breeding perspective. (Eds.) Reynolds, M. P., J. I. Ortiz-Monasterio y A. McNab. CIMMYT. Mexico, D.F. 11-16.
- 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.
- Kou, L.; D. Labrie y P. Chylek. 1993. Refractive indices of water and ice in the 0.65- to 2.5- $\mu\text{m}$  spectral range. *Applied Optics*, 32(19): 3531-3540.
- Lazaridis, D. C.; J. Verbesselt y A. P. Robinson. 2010. Penalized regression techniques for prediction: a case study for predicting tree mortality using remotely sensed vegetation indices This article is one of a selection of papers from Extending Forest Inventory and Monitoring over Space and Time. *Canadian Journal of Forest Research*, 41(1): 24-34.
- Liu, J.; E. Pattey; J. R. Miller; H. McNairn; A. Smith y B. Hu. 2010. Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model. *Remote Sensing of Environment*, 114(6): 1167-1177.

Loss, S. P. y K. H. M. Siddique. 1994. Advances in Agronomy: Morphological and physiological traits associated with wheat yield increases in mediterranean environments (Ed.) Donald, L. Sparks. Academic Press. 229-276.

Miller, A. J. 1984. Selection of subsets of regression variables. *Journal of the Royal Statistical Society. Series A (General)*, 147(3): 389-425.

Monneveux, P.; C. Sanchez y A. Tiessen. 2008. Future progress in drought tolerance in maize needs new secondary traits and cross combinations. *The Journal of Agricultural Science*, 146(03): 287-300.

Peñuelas, J. y I. Filella. 1998. Visible and near-infrared reflectance techniques for diagnosing plant physiological status. *Trends in Plant Science*, 3(4): 151-156.

Peñuelas, J.; I. Filella; C. Biel; L. Serrano y R. Savé. 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. y Y. Inoue. 1999. Reflectance indices indicative of changes in water and pigment contents of peanut and wheat leaves. *Photosynthetica*, 36(3): 355-360.

Peñuelas, J.; J. Pinol; R. Ogaya y I. Filella. 1997. Estimation of plant water concentration by the reflectance Water Index WI (R900/R970). *International Journal of Remote Sensing*, 18(13): 2869-2875.

Rebetzke, G. J.; A. G. Condon; R. A. Richards y G. D. Farquhar. 2002. Selection for reduced carbon isotope discrimination increases aerial biomass and grain yield of rainfed bread wheat. *Crop Science*, 42(3): 739-745.

Richards, R. 1982. Breeding and selecting for drought resistance in wheat. *Drought resistance in crops with emphasis on rice*: 303-316.

Richards, R. A. 1996. Defining selection criteria to improve yield under drought. *Plant Growth Regulation*, 20(2): 157-166.

Royo, C.; N. Aparicio; D. Villegas; J. Casadesus; P. Monneveux y J. L. Araus. 2003. Usefulness of spectral reflectance indices as durum wheat yield predictors under contrasting Mediterranean conditions. *International Journal of Remote Sensing*, 24(22): 4403-4419.

Seelig, H. D.; A. Hoehn; L. S. Stodieck; D. M. Klaus; W. W. Adams Iii y W. J. Emery. 2008. The assessment of leaf water content using leaf reflectance ratios in the visible, near-, and short-wave-infrared. *International Journal of Remote Sensing*, 29(13): 3701-3713.

Serrano, L.; S. L. Ustin; D. A. Roberts; J. A. Gamon y J. Peñuelas. 2000. Deriving water content of chaparral vegetation from AVIRIS data. *Remote Sensing of Environment*, 74(3): 570-581.

Sims, D. A. y J. A. Gamon. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81(2-3): 337-354.

Weber, V. S.; J. L. Araus; J. E. Cairns; C. Sanchez; A. E. Melchinger y E. Orsini. 2012. Prediction of grain yield using reflectance spectra of canopy and leaves in maize plants grown under different water regimes. *Field Crops Research*, 128(0): 82-90.

## CAPÍTULO II

### **EVALUACION DEL RENDIMIENTO EN GENOTIPOS DE TRIGO HARINERO (*Triticum aestivum*) USANDO LONGITUDES DE ONDA CORRESPONDIENTES AL ESPECTRO VISIBLE, ROJO CERCANO Y ROJO MEDIO BAJO TRES CONDICIONES HÍDRICAS.**

#### **1 RESUMEN**

El mejoramiento de cultivos basado en rendimiento es altamente costoso y demandante de tiempo, por lo que métodos que lo estimen en forma indirecta representan una valiosa alternativa. La estimación del rendimiento a partir de la reflectancia de la canopia, representa una herramienta potencialmente adecuada, sin embargo los actuales acercamientos han sido limitados y variables en sus estimaciones. En el presente estudio se evaluó la capacidad predictiva del modelo multivariado Ridge Regression (RR) en la estimación del rendimiento a partir de datos de reflectancia medidos en antesis y durante el llenado de grano en 368 genotipos de trigo harinero, los cuales fueron evaluados en tres ambientes (estrés severo, estrés medio y riego completo) los cuales obtuvieron rendimientos promedios de 1655, 4739 y 7967 kg ha<sup>-1</sup>, respectivamente. Los modelos generados para cada fecha de medición y ambiente explicaron entre el 77,0% y 90,9% de la variación del rendimiento, encontrándose la mayor correlación en llenado de granos en el ambiente de estrés severo. Al combinar los modelos para cada estado de desarrollo, los coeficientes de determinación subieron a 89,9% para antesis y 92,0% para llenado de granos. Cuando se utilizaron los modelos generados en cada ambiente y estado fenológico para estimar el rendimiento en los otros ambientes y estados, los modelos generados en antesis fueron los que en promedio, predijeron mejor el rendimiento en todos los ambientes. De este modo, técnicas de modelamiento multivariados basadas en información espectral representan una herramienta válida para la discriminación de genotipos en diferentes ambientes y estados fisiológicos.

## 2 ABSTRACT

Plant breeding based on grain yield is a very expensive and time consuming method. For such reason, novel techniques able to estimate grain yield in an indirect way represent a valuable alternative for improve yields crops. Estimation of grain yield based in the canopy reflectance, represent a potential adequate tool, however, the current approaches have been limited and unstable in their predictions. In the present work was evaluated the capacity of the multivariate model Ridge Regression (RR) to predict grain yield based on reflectance data in 368 genotypes of spring wheat (*Triticum aestivum* L.) with measurements during anthesis and grain filling. The plants where evaluated in three different location conditions (severe stress, medium stress and complete irrigation).The grain yield average for each condition was 1655, 4739 y 7967 kg ha<sup>-1</sup>, respectively. The models generated from reflectance data for each phenological stage and water availability explained between 77% and 90,9% of the grain yield variation, finding the best correlation in grain yield in the severe stress water condition. When the data of the locations was combined for each phenological stage, the determination coefficients (R<sup>2</sup>) climbed to 89,9% and 92% for anthesis and grain filling, respectively. When models obtained from all the locations and water conditions were used to estimate grain yield in each of the other locations, models generated from anthesis showed the best performance.. Thereby, the use of multivariate regression models based on spectral reflectance represents a valid tool to discriminate genotypes under different locations and phenological stages.

### 3 INTRODUCCIÓN

Habitualmente, las estrategias de mejoramiento consisten en la comparación de genotipos que tengan altos rendimientos, lo cual conlleva a una evaluación dentro y entre un gran número de poblaciones segregantes derivadas de diversos cruzamientos (Ball y Konzak, 1993). Sin embargo, este tipo de ensayos usualmente requieren ser repetidos durante varios años, lo que implica costos operativos elevados así como también un alto consumo de tiempo asociado principalmente a las mediciones (Royo *et al.*, 2003). Además, estos acercamientos empíricos en base al rendimiento han sido modestos en ambientes mediterráneos de secano, debido principalmente, a que el factor más limitante al rendimiento, el estrés hídrico, afecta la última parte de desarrollo del cultivo (Acevedo *et al.*, 1999; Richards, 1982). Por otro lado, se ha demostrado que la selección por rendimiento tiene baja heredabilidad y alta interacción genotipo medio ambiente (Araus *et al.*, 2002; Blum, 1988). De este modo, la generación de métodos que logren estimar el rendimiento en estados iniciales o intermedios de desarrollo, representan una valiosa herramienta para condiciones de limitación hídrica. Además, esta metodología debe ser rápida y certera para predecir el rendimiento entre diferentes genotipos antes de cosecha y así optimizar los costos y el tiempo requerido para la evaluación del rendimiento en los programas de mejoramiento (Araus *et al.*, 2001).

En agricultura y otras áreas, existen numerosos sensores que pueden detectar la energía electromagnética que es reflejada o emitida por una superficie. En plantas, las hojas y canopia, estructuras foto-sintetizadoras de la planta, interactúan con la radiación incidente y pueden absorber, reflejar o transmitir la energía que llega a su superficie, mediante la interacción de la radiación con la estructura de la planta y el contenido de pigmentos fotosintéticos (Gates *et al.*, 1965). No obstante, los datos obtenidos desde estos aparatos solo pueden ser interpretados si se conocen las bases de interacción entre la energía incidente con la superficie a estudiar (Knipling, 1970). Mediciones de la firma espectral o reflectancia de la canopia y las hojas han sido vinculadas con estimaciones de caracteres de la planta tales como contenido de clorofila (Sims y Gamon, 2002), biomasa aérea (Liu *et al.*, 2010), contenido de agua en la planta (Peñuelas *et al.*, 1993a) y rendimiento (Aparicio *et al.*, 2000), principalmente.

Las estimaciones de diferentes caracteres fisiológicos (índice de área foliar, índice de verdor, materia seca, etc) asociados al rendimiento pueden ser logradas mediante el uso de índices asociados a diferentes longitudes de onda, llamados índices de reflectancia espectral (IREs), los cuales están basados sobre simples operaciones o relaciones entre la reflectancia de la canopia a determinadas longitudes de onda (Aparicio *et al.*, 2000; Araus, 1996; Peñuelas y Filella, 1998). Entre los índices más utilizados en la estimación de caracteres fisiológicos se encuentran el índice de vegetación de diferencias normalizado [NDVI;  $(R900 - R680) / (R900 + R680)$ ] (Araus *et al.*, 2002; Peñuelas y Filella, 1998) y el de razón simple [SR;  $(R900 / R680)$ ] (Aparicio *et al.*, 2000; Serrano *et al.*, 2000b). Ambos índices han sido correlacionados positivamente (tanto en base logarítmica como lineal) con la masa seca del cultivo (MS), índice de área foliar (IAF), índice de área verde (IAV) y la capacidad de fotosíntesis potencial (Aparicio *et al.*, 2000; Araus *et al.*, 2002; Peñuelas y Filella, 1998). Sin embargo, estos índices utilizan una información limitada de la firma espectral por lo

que reduce, simplifica o no considera la amplia información contenida en esta. Además, la eficiencia con la cual este tipo de índices discrimina genotipos varía significativamente entre plantas y ecosistemas (Gamon *et al.*, 1995). Por otro lado, las longitudes utilizadas para la estimación de caracteres, tales como el rendimiento, pueden variar de acuerdo al estado fenológico y las condiciones ambientales (Weber *et al.*, 2012).

Como una forma de solucionar los problemas asociados al uso de pequeñas áreas de la firma espectral, se ha propuesto la utilización de la totalidad de la información proveniente de los sensores remotos. Los primeros acercamientos han sido mediante regresiones lineales, basadas en los mínimos cuadrados ordinarios. Sin embargo, debido a que los datos recolectados desde estos sensores tienen una alta dimensionalidad y una alta colinearidad entre ellos, muchas de estas correlaciones han sido erróneas o no significativas (Lazaridis *et al.*, 2010). Por este motivo, las técnicas de regresión basadas en la penalización de los parámetros de la regresión, las cuales generan modelos de regresión multivariadas, son más adecuadas para estimar las correlaciones entre muchas variables explicatorias y variables respuesta (Cai *et al.*, 2009). No obstante, Ferrio *et al.* (2005) sostiene que este tipo de acercamiento debe ser comprobado empíricamente en campo, ya que las bases sobre las cuales están hechas las relaciones entre las longitudes de onda y el rendimiento no están completamente entendidas y pueden variar por ambiente y localidad. En trigo duro (Ferrio *et al.*, 2005) y maíz (Weber *et al.*, 2012), se ha evaluado la predicción del rendimiento mediante técnicas multivariadas, utilizando una técnica basada en *Partial Least Square Regression* (PLSR). Esta técnica descompone toda la variabilidad de la información espectral en pocos factores que determinan el rendimiento, obteniéndose resultados correctos. En esta línea, existen otras metodologías que logran utilizar la totalidad de la información generada por las mediciones espectrales, como la Regresión Ridge, introducida por Tikhonov (1943) y masificada por Hoerl y Kennard (1970a); Hoerl y Kennard (1970b). Este tipo de regresión lineal multivariada, incluye una contracción de los coeficientes de la regresión del modelo multivariado, reduciéndolos en igual magnitud, mediante la incorporación de un factor de penalización o de contracción de los estimadores (Lazaridis *et al.*, 2010).

En este contexto, nuevas metodologías que manejen un amplio rango de información proveniente de la reflectancia de la canopia, deben ser estudiadas para identificar su potencial uso en la estimación de rendimiento, siendo el principal objetivo de este estudio el comparar la predicción de rendimiento en genotipos de trigo harinero a partir del uso de la totalidad de longitudes de onda del espectro de onda corta con respecto a los índices tradicionales de reflectancia bajo dos condiciones hídricas en dos estados de desarrollo.

## **4 HIPOTESIS DE TRABAJO**

El uso de bandas espectrales en el rango óptico mejora las predicciones de rendimiento con respecto a índices de reflectancia tradicionales en genotipos de trigo harinero.

## **5 OBJETIVOS**

### **5.1 Objetivo general.**

Comparar la predicción de rendimiento en genotipos de trigo harinero a partir del uso de las bandas espectrales del rango óptico con respecto a los índices tradicionales de reflectancia bajo tres condiciones hídricas.

### **5.2 Objetivos específicos.**

- Evaluar la eficiencia en la predicción de rendimiento mediante el uso de IREs en 368 genotipos de trigo harinero bajo tres condiciones hídricas.
- Evaluar la eficiencia en la predicción del rendimiento mediante el uso de las bandas espectrales del rango óptico en 368 genotipos de trigo harinero bajo tres condiciones hídricas.
- Comparar las predicciones de rendimiento provenientes de ambos métodos.

## 6 Materiales y Métodos

### 6.1 Sitios de estudio

Durante la temporada 2011-2012 se realizaron tres ensayos en dos sitios de estudio. El primer sitio correspondió a la Estación Experimental Santa Rosa y el segundo correspondió a la Estación Experimental de Cauquenes, ambos ubicados en la región del Maule. La descripción de cada sitio y características agroclimáticas se presentan en el Cuadro 1.

Cuadro 1. Características agroclimáticas de los sitios de ensayo.

	<b>Sta Rosa</b>	<b>Cauquenes</b>
Latitud	36°32' m latitud sur	35°58' latitud sur
Longitud	71°55' longitud oeste	72°17' longitud oeste
T° media anual	14,0°C	15,2°C
T° Max	28,8°C	31,3°C
T° Min	3,5°C	4,6°C
pp Anual	1025 mm	641,7 mm
Tipo Suelo	Andisol	Alfisol
Textura	Franco-limosa	Arcilloso
Profundidad	Muy Profundos	Profundos
pp Temporada	565,5 mm	338,8 mm

### 6.2 Ensayos

Los 368 genotipos fueron evaluados en tres condiciones hídricas. Estrés severo (ES), localizado en Cauquenes, estrés medio (EM) y riego completo (RC) localizados en Sta Rosa. El riego fue realizado mediante la utilización de surcos. En la condición de riego completo se realizaron 4 riegos durante macolla (Z21), emergencia hoja bandera (Z37), espigadura (Z50) y llenado de granos (Z70). En la condición de estrés medio, se realizó sólo un riego en el periodo de macolla (Z21). Cada riego fue de aproximadamente 50 mm. Los genotipos sometidos a estrés severo no fueron regados.

### 6.3 Tratamientos

Los tratamientos fueron 368 líneas avanzadas de trigo harinero primaveral provenientes de CIMMYT, INIA Chile e INTA Uruguay, adaptadas a las condiciones de evaluación. Para completar los 400 genotipos requeridos por el diseño se sembraron los genotipos Don Alberto y Carpintero.

## 6.4 Diseño Experimental

El diseño experimental corresponde a un alfa lattice de 20 sub bloques con 20 genotipos por sub-bloques con dos repeticiones por cada condición hídrica. Cada unidad experimental estuvo constituida por 5 hileras de 2 m de largo separadas a 20 cm cada una.

## 6.5 Manejo del cultivo

Los genotipos se sembraron el 31 de Agosto y el 07 de Septiembre del 2011, para Sta Rosa y Cauquenes, respectivamente, con una densidad de siembra de  $200 \text{ kg ha}^{-1}$ . La fertilización previa a la siembra, según análisis químico fue de  $260 \text{ kg ha}^{-1}$  de fosfato de amonio (46%  $\text{P}_2\text{O}_5$  y 18% de N),  $90 \text{ kg ha}^{-1}$  de cloruro de potasio (60%  $\text{K}_2\text{O}$ ),  $200 \text{ kg ha}^{-1}$  de sulphomag (22%  $\text{K}_2\text{O}$ , 18% de MgO y 22 % S),  $10 \text{ Kg ha}^{-1}$  de boronatrocalcita (11% B),  $3 \text{ kg ha}^{-1}$  de sulfato de zinc (35% zinc). Durante macollaje se realizó una aplicación de  $153 \text{ kg ha}^{-1}$  de N en forma de urea. El control de malezas se realizó mediante la aplicación de de flufenacet + flurtamone + diflufenican ( $\text{gr i.a ha}^{-1}$ ) en pre emergencia y otra aplicación de MCPA ( $525 \text{ gr i.a ha}^{-1}$ ) más Metsulfurón-methyl ( $8 \text{ gr i.a ha}^{-1}$ ) en post emergencia.

## 6.6 Mediciones

**Reflectancia:** La reflectancia de la canopia fue medida con un espectroradiómetro marca: ASD Modelo: FieldSpec ® 3 Jr (Boulder, CO 80301 USA). La medición del instrumento comprende 2150 bandas continuas con intervalos de medición cada 1 nm, desde los 350 a los 2500 nm. De este modo se cubre el espectro ultra violeta, visible, infrarrojo cercano e infrarrojo medio. El espectro de reflectancia de la canopia fue calculado en tiempo real como la relación entre el espectro de radiación incidente versus el reflejado. El espectro de radiación incidente fue obtenido periódicamente desde la luz reflejada por una superficie de color blanco llamada Spectralon®.

Las mediciones de reflectancia de la canopia fueron realizadas para cada uno de los 368 genotipos ajustando el espectroradiómetro a 70 cm sobre la parte más alta de la canopia, con un ángulo de disparo de  $45^\circ$  y un campo de visión del lente de  $50^\circ$ .

Las mediciones fueron realizadas para cada genotipo en dos etapas fenológicas: (i) espigadura en Sta Rosa (22 Noviembre 2011) y llenado de granos en Cauquenes (13 Diciembre, 2011) y Sta Rosa (21 Diciembre, 2011). Se realizaron tres evaluaciones en cada unidad experimental. Las mediciones fueron realizadas dos horas antes (12:00 pm) y dos horas después (16:00 pm) del cenit (14:00 pm).

**Rendimiento:** Para determinar el rendimiento, se cosechó a ras de suelo la parcela completa de 2 m<sup>2</sup>. Posteriormente la parcela fue trillada y se separó el grano del resto de la planta. Los valores desde la parcela experimental que estaban expresados en gr m<sup>-2</sup>, fueron multiplicados por 0,5 para transformarlos a kg ha<sup>-1</sup>. Posteriormente, se procedió a calcular el coeficiente de correlación de Pearson (r) entre el rendimiento y cada longitud de onda.

## 6.7 Genotipos contrastantes

A partir de cada ambiente y estado de desarrollo, se compararon las firmas espectrales de los 15 genotipos con mayores rendimientos y los 15 de menores rendimientos.

## 6.8 Índices de reflectancia espectral (IREs)

Se calcularon los siguientes índices de reflectancia espectral los cuales han sido ampliamente utilizados en numerosos estudios:

Índice	Longitudes de Onda	Aplicaciones	Referencia
Simple Ratio	$SR = R_{NIR} / R_{red}$	Biomasa, IAF, Cobertura	Gamon <i>et al</i> (1995)
Normalized Difference Vegetation Index	$NDVI = (R_{NIR} - R_{red}) / (R_{NIR} + R_{red})$	PAR interceptada, cobertura	Gamon <i>et al</i> (1995)
Photochemical Reflectance Index	$PRI = (R_{550} - R_{531}) / (R_{550} + R_{531})$	Eficiencia de captura de radiación	Peñuelas <i>et al</i> (1995)
Water Index	$WI = R_{900} / R_{970}$	Contenido hídrico de la planta	Peñuelas <i>et al</i> (1997)

Se determinaron los coeficientes de correlación de Pearson (r) entre los IREs calculados para los dos estados fenológicos y el rendimiento. Posteriormente, se determinó cual o cuales IREs tiene(n) la mejor correlación con el rendimiento en cada uno de los estados de desarrollo y en ambas condiciones hídricas.

## 6.9 Generación del modelo predictivo

**Bandas Utilizadas:** Para realizar los análisis, se utilizaron las bandas comprendidas entre las longitudes de onda 350 y 2500 nm. Algunas longitudes de onda fueron eliminadas manualmente del modelo cuando presentaron una alta variabilidad en sus magnitudes o al estar fuera de rango. Además, los datos obtenidos desde el espectroradiómetro, fueron estandarizados para corregir cambios estructurales asociados a variaciones ambientales, atmosféricas, de las plantas u otros para que la información desde fuentes biológicamente equivalentes pueda ser comparada. Para ello, las longitudes de onda fueron centradas en su media pero no escalada, usando la variación estándar normal (SNV) descrita por Randolph

(2006). Se usaron todas las parcelas dentro de cada ensayo para calibrar el modelo. Los modelos fueron identificados de acuerdo al ambiente en el cual fueron realizados y el estado fenológico en que fueron medidos.

**Regresión Ridge:** Para determinar la relación entre la reflectancia de la canopia y el rendimiento se utilizó un modelo de regresión multivariado conocido como Regresión Ridge (Hastie *et al.*, 2005). Esta regresión lineal multivariada, localiza la suma de cuadrados mínima de la predicción, mientras que al mismo tiempo limita la suma de los cuadrados de los coeficientes de la regresión. Dado que existen muchas variables predictoras, donde además algunas están correlacionadas, este tipo de regresiones resuelve el problema al incluir un valor de penalización, sobre los coeficientes de la regresión, al momento de ser estos determinados en la matriz de vectores.

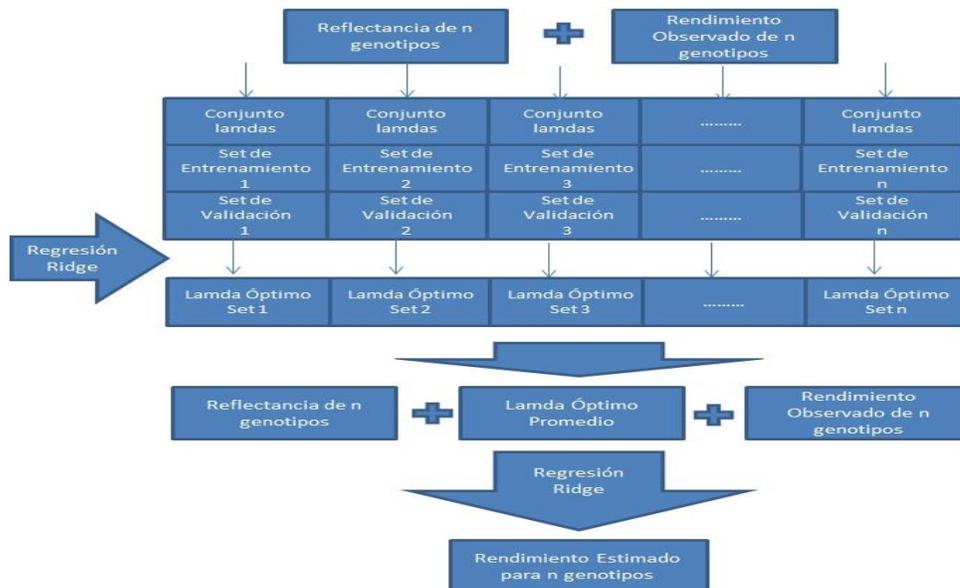
El criterio que realiza la minimización de los coeficientes es:

$$RSS(\lambda) = \sum_{i=1}^n \left( y_i - \hat{y}_i \right)^2 + \lambda \sum_{j=1}^p \beta_j^2$$

Donde  $RSS$  es el residual de la suma de cuadrados,  $\lambda$  controla el grado de penalización de los coeficientes de regresión,  $n$  es el número de observaciones,  $y$  es la variable dependiente,  $\hat{y}$  es la predicción de la regresión,  $p$  es el número de variables dependientes (longitudes de onda) y  $\beta_j$  es el valor del el  $j$ -esimo coeficiente.

**Validación Cruzada:** El valor óptimo de  $\lambda$  para las funciones de regresión Ridge, se determinó usando la validación cruzada generalizada (GCV). Esta forma de aproximación separa del total de observaciones un grupo de datos llamado de entrenamiento (300 genotipos) y otro grupo de datos llamados de validación (100 genotipos). En este último grupo se realiza la validación cruzada de los modelos lineares.

A partir del grupo de observaciones de entrenamiento se generaron tantos modelos lineales como lambdas ( $\lambda$ ) hayan sido seleccionados aleatoriamente para predecir el rendimiento. Posteriormente, cada uno de los modelos generados desde el set de calibración fue evaluado mediante el set de validación, donde se obtuvo el valor de GCV, el cual corresponde al coeficiente de determinación que precisó el valor de ajuste del modelo en el grupo de validación. Para obtener el mejor modelo, se consideró el valor de lambda que maximice la predicción de rendimiento, evaluado mediante el coeficiente de determinación de la GCV. Para asegurar una correcta selección del parámetro lambda, se procedió de manera iterativa la consideración de 20 conjuntos de datos seleccionados aleatoriamente (Figura 1).



**Figura 1.** Procesos utilizados para la obtención del lambda óptimo del modelo de regresión ridge.

**Coefficientes de regresión:** Para cada una de las longitudes de onda se calculó su respectivo coeficiente de regresión dentro del modelo. Para lograr una mejor comparación, los coeficientes fueron re-escalados dividiéndolos por el valor máximo encontrado en cada uno de los modelos.

**Comparación de modelos:** Para realizar una correcta comparación entre los modelos generados en los distintos ensayos y estados, se calculó el  $R^2$  y la raíz del error cuadrático de la media (RMSE) para cada uno de los modelos:

$$RMSE = \sqrt{\frac{\sum (Y_{ref} - Y_{est})^2}{N - 1}}$$

donde  $Y_{ref}$  corresponde al rendimiento observado,  $Y_{est}$  corresponde al rendimiento predicho por el modelo y  $N$  es el número de observaciones. Con este estadístico se procederá a calcular el RMSE relativo (rRMSE) para cada modelo, el cual se define como la relación entre RMSE y el error estándar del rendimiento dentro de cada ensayo (Ferrio *et al.*, 2005). A menor relación, mayor poder de predicción del modelo para detectar diferencias en rendimiento en el ensayo.

### 6.9.1 Análisis estadístico

Todos los análisis estadísticos fueron conducidos en el programa R-project 3.01 (R\_Core\_Team, 2012). Los modelos basados en regresión ridge, las estimaciones de GCV

y los valores de  $\lambda$  fueron realizados usando la función `ridge.lm` (Venables y Ripley, 2002) en la librería MASS de R.

## 7 Resultados

### 7.1 Rendimiento de los genotipos en los diferentes ambientes.

El promedio de los rendimientos entre los diferentes ambientes varió de acuerdo a las reducciones de aporte hídrico para cada una de las condiciones (Cuadro 2). Los rendimientos para las condiciones de estrés severo (ES), estrés medio (EM) y riego completo (RC) fueron de 1655, 4739 y 7967 kg ha<sup>-1</sup>, respectivamente. El máximo rendimiento se encontró en el ambiente de riego completo y el menor en el ambiente de estrés severo. En la condición de riego, se observó la desviación estándar más alta y el menor coeficiente de variación, caso contrario a lo sucedido bajo la condición de estrés severo. Las precipitaciones durante el desarrollo del cultivo fueron de 338,8 mm y 565,5 mm para Cauquenes y Sta Rosa, respectivamente.

Cuadro 2. Parámetros principales de los rendimientos en los diferentes ambientes.

Variable	n	Media	Mín	Máx	D.E.	CV (%)
Riego Completo	397	7967	2240	12992	1788,4	22,5
Estrés Medio	399	4739	607	10144	1425,8	30,1
Estrés Severo	391	1655	130	4394	696,1	42,1

Media, Min, Max, DE en kg ha<sup>-1</sup>

### 7.2 Firma espectral y su relación con el rendimiento.

Al evaluar las correlaciones entre la reflectancia de los 368 genotipos de trigo con el rendimiento, mediante del coeficiente de Pearson (r), se encontraron correlaciones significativas en diferentes zonas de la firma espectral (Figura 2). En la zona del espectro visible (400 a 700 nm), se observó una correlación negativa con el rendimiento en todos los ambientes, siendo la condición de EM medida en antesis, la que tuvo en promedio el valor más alto ( $r = -0,55$ ). En la zona del infrarrojo cercano (NIR), área comprendida entre los 700 y 1100 nm, se observó un cambio en el signo de la correlación entre rendimiento y las longitudes en esta zona, con coeficientes de correlación positivos en todos los ambientes. Para estas longitudes, la condición de RC medida en llenado de granos, fue la que mostró en promedio el valor más alto de correlación ( $r = 0,63$ ). Dentro de la zona del infrarrojo de onda corta (SWIR), zona comprendida entre 1100 y 1300 nm, se observó una variación en el signo de la correlación, la cual era dependiente del ambiente, encontrándose valores positivos para RC-AN, RC-LLG y ES-LLG y valores negativos para EM-AN y EM-LLG. En las longitudes de onda superiores a los 1400 nm, todos los ambientes tuvieron coeficientes de correlación negativos, siendo el ambiente de ES-LLG ( $r = -0,65$ ), el que mostró el más alto valor de correlación en promedio.

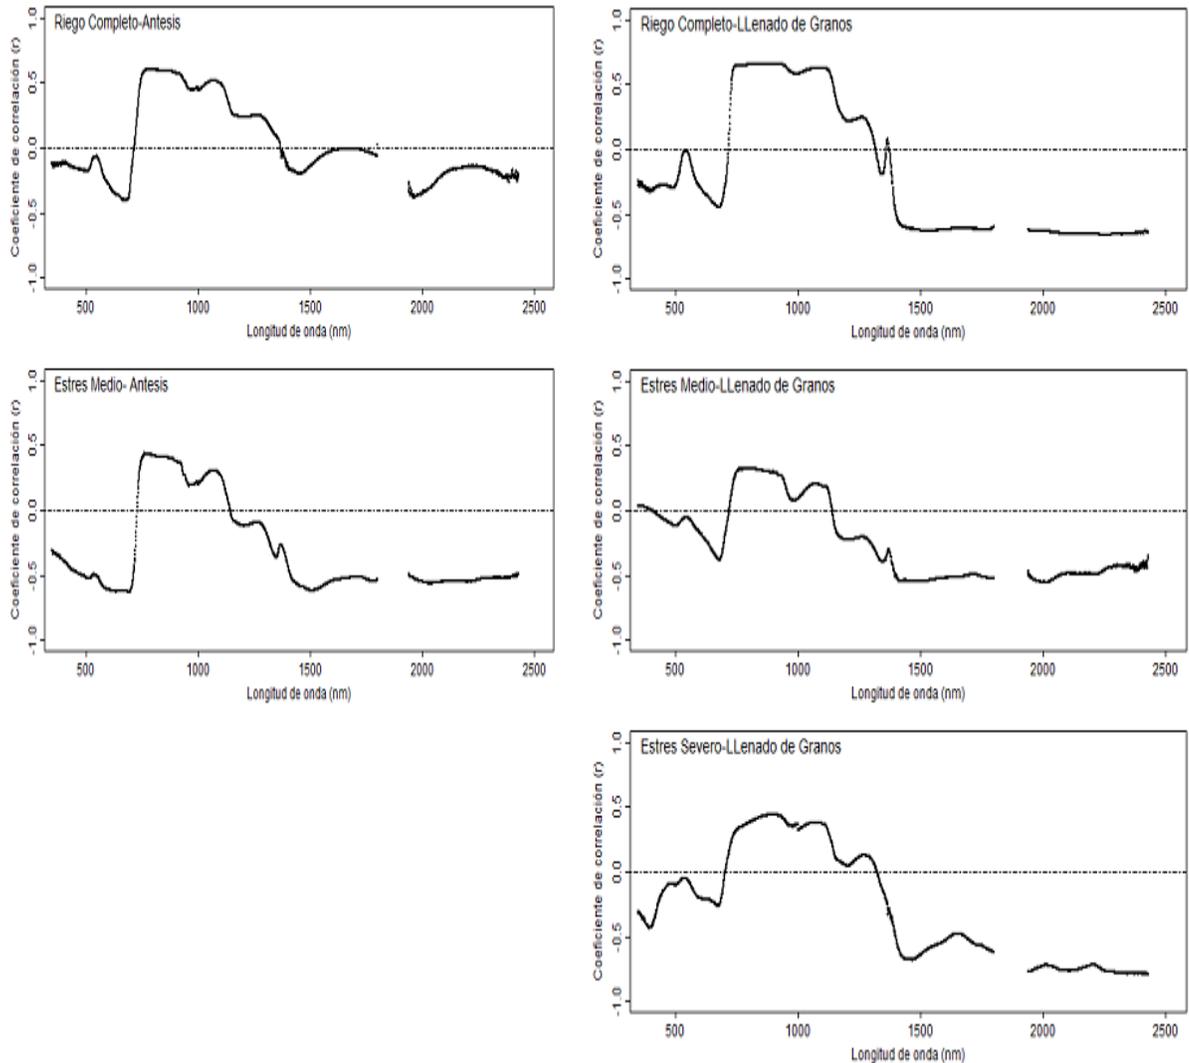


Figura 2. Coeficiente de correlación de Pearson ( $r$ ) entre rendimiento y longitudes de onda de la firma espectral para cada ambiente y estado fenológico.

### 7.3 Características de la firma espectral asociadas al rendimiento.

En el análisis comparativo de las firmas espectrales de los 15 genotipos con mayor y menor rendimiento en cada uno de los ambientes y estados fenológicos, se observaron diferencias en los valores de reflectancia para algunas longitudes de onda dentro de la firma espectral (Figura 3). Los genotipos con mayores rendimientos mostraron menores valores de reflectancia en la zona entre los 400 a 750 nm para todos los ambientes a excepción del ES. El ambiente que contrastó en mejor medida las diferencias entre los genotipos, fue el EM en antesis. Para la zona cercana a los 550 nm, en los dos estados de desarrollo de la condición de RC, no se observaron diferencias en la reflectancia. Esta situación fue contraria en EM, donde las diferencias en las magnitudes para esta zona fueron notorias, siendo antesis el estado que mostró las diferencias más contrastantes, con valores más altos de reflectancia

en los genotipos de bajo rendimiento. Para la situación de ES, las diferencias fueron menos marcadas en comparación a los demás ambientes y en el área cercana a los 550 nm, mostró tendencias opuesta a EM con valores más altos para los genotipos de alto rendimiento.

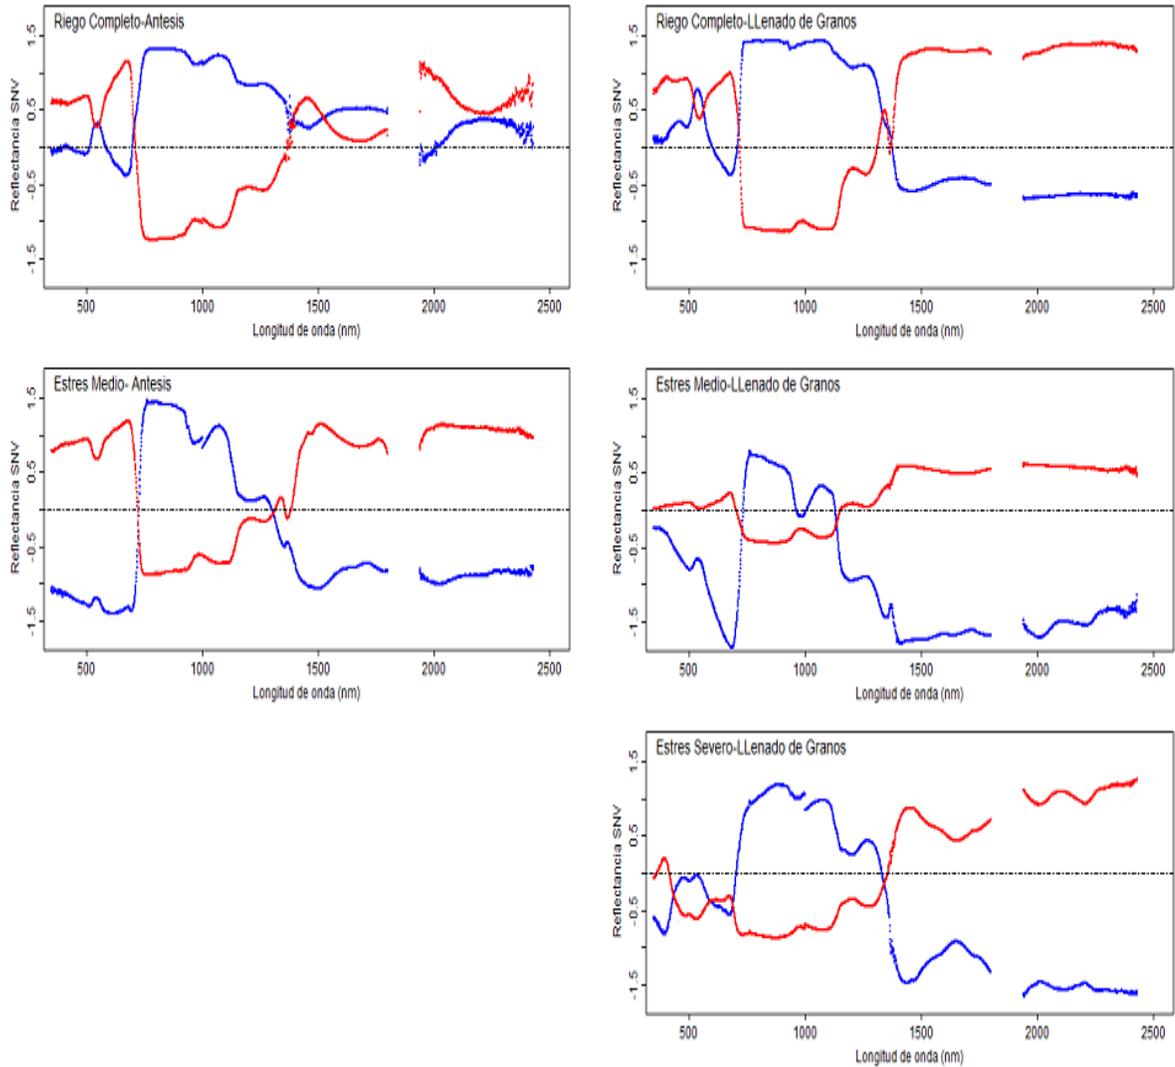


Figura 3. Reflectancia estandarizada (SNV) de los 15 genotipos de mayor y menor rendimiento. Datos corresponden a todos los ambientes y estados evaluados.

Se observó, que la reflectancia de la zona correspondiente al Red Edge (700 nm - 800 nm), puede discriminar entre los diferentes genotipos para todos los ambientes. En los genotipos de alto rendimiento se observó un rápido cambio desde coeficientes de valores negativos a valores positivos, mientras que para los de bajo rendimiento se observó rápido cambio en forma inversa. Para la región del NIR entre los 800 a 1200 nm, la reflectancia de los genotipos con mayores rendimientos fue más alta, siendo la condición de riego óptimo la que en promedio mostró los valores más altos para los dos estados fenológicos. En las longitudes de onda correspondientes al infrarrojo de onda corta o “Short Wave Infrared” SWIR (1200 a 2400 nm), se observó en general, que los genotipos con alto rendimiento en

los tres ambientes, mostraron una menor reflectancia en promedio para esta zona en comparación con los de bajo rendimiento.

#### 7.4 Utilización de IREs para estimación de rendimiento.

Se evaluó el grado de correlación entre los IREs más usados en la literatura con el rendimiento en los diferentes ambientes y estados de desarrollo. En el ensayo se encontraron coeficientes de determinación entre 0,0% y 72,4% en los diferentes ambientes (Cuadro 3). Los índices WI, NDVI, y SR tuvieron mayores coeficientes de determinación con rendimiento en EM-AN, RC-LLG y EM-LLG. Sin embargo, en el ambiente de ES-LLG no hubo correlación de estos índices con el rendimiento o bien estos fueron bajos, como es el caso de WI. En general, el IREs WI fue el que tuvo una mejor estimación del rendimiento.

Cuadro 3. Coeficientes de determinación ( $R^2$ ) entre IREs y rendimiento para los ambientes.

	NDVI	PRI	WI	SR
RC-AN	4,0 ***	4,8 ***	7,3 ***	3,6 ***
EM-AN	32,5 ***	42,3 ***	56,3 ***	39,7 ***
RC-LLG	31,4 ***	9,6 ***	51,8 ***	16,0 ***
EM-LLG	49,0 ***	0,0 NS	62,4 ***	41,0 ***
ES-LLG	0,6 NS	1,0 NS	5,3 ***	0,4 NS

$p < 0,05$  \*;  $p < 0,01$  \*\*;  $p < 0,001$  \*\*\*; ns = no significativo

#### 7.5 Modelo multivariado y pesos relativos de las longitudes.

Cuando se analizó el peso relativo de los coeficientes de regresión obtenidos desde el modelo de Regresión Ridge (Figura 4), se observó una variabilidad en la magnitud de los coeficientes para las diferentes longitudes de onda que fue dependiente tanto del ambiente como del estado fenológico. Para las longitudes de onda comprendidas entre los 400 a 750 nm, los coeficientes de los modelos mostraron valores tanto positivos como negativos. Dentro de esta zona, las longitudes de onda comprendidas entre los 480 y 550 nm en todos los modelos, mostraron valores positivos en sus coeficientes de regresión asignados por el modelo, en cambio para la zona de los 550 a 570 nm, los coeficientes de los ambientes con estrés hídrico mostraron valores negativos mientras que en el ambiente de riego, mantuvo su signo positivo. En la zona del Red-Edge (700 – 800 nm), los valores de los coeficientes fueron negativos en todos los ambientes, no obstante en el estado de llenado de granos de EM, los valores de los coeficientes fueron negativos y a partir de 740 nm fueron positivos. En el área de reflectancia comprendida entre los 950-1000 nm se encontraron valores negativos para los coeficientes en el ambiente regado y positivos para los ambientes con estrés hídrico, manteniendo el signo de los coeficientes en los dos estados de desarrollo muestreados. En la zona comprendida entre los 1100 a 2500 nm se encontraron valores de coeficientes que dependían tanto del ambiente como del estado de desarrollo. En los 1100 nm, se encontró que para antesis los valores de los coeficientes fueron cercanos a 0 en los

dos ambientes medidos, sin embargo, cuando la medición fue realizada en llenado de granos, los coeficientes mostraron valores positivos en los tres ambientes. En el caso de los 1240 nm, los ambientes de riego en ambos estados de desarrollo mostraron valores cercanos a 0, sin embargo, en condiciones de estrés hídrico, estos tomaron valores negativos. Para las longitudes de onda comprendidas entre los 2000 a 2400 nm, no se observó un patrón de los valores de los coeficientes de regresión que pueda ser asumido como efecto de ambiente o estado fenológico.

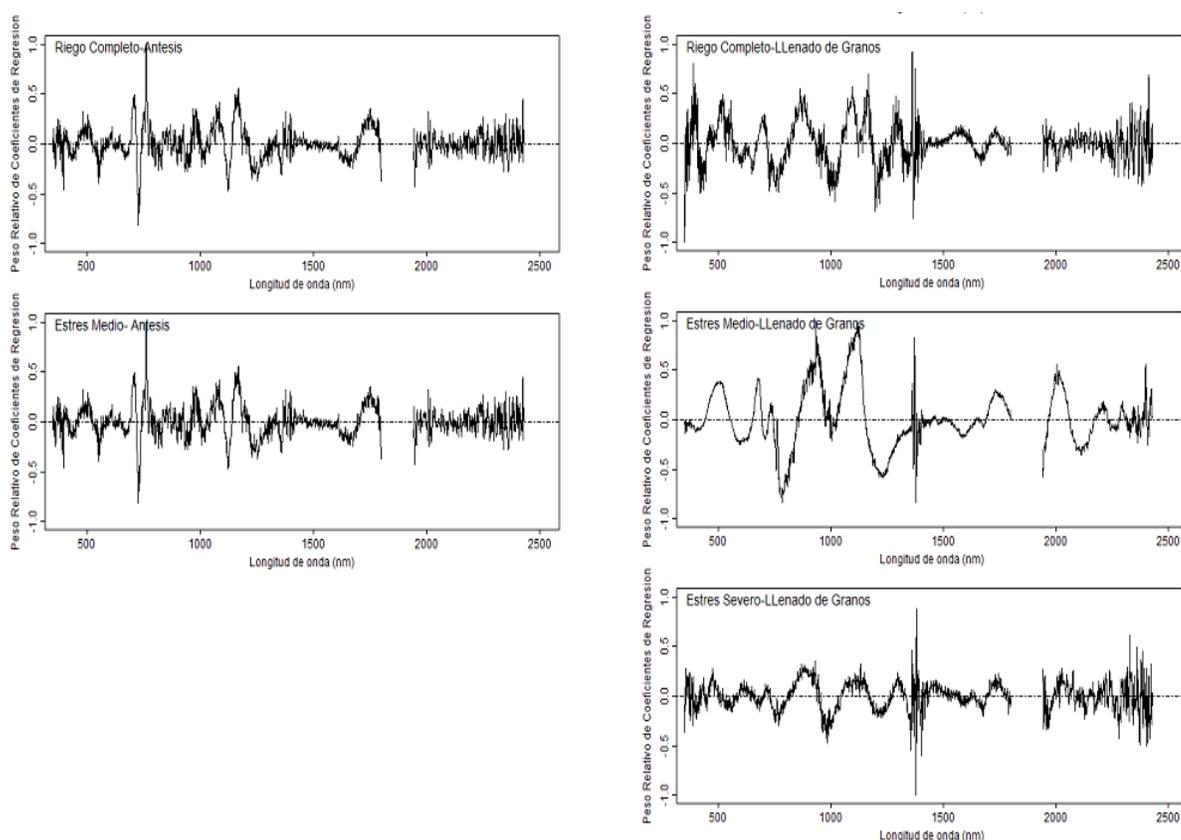


Figura 4. Peso Relativo de Coeficientes de regresión de para cada una de las longitudes de onda. Los coeficientes fueron generados luego de la calibración para cada uno de los ambientes y estados fenológicos evaluados.

## 7.6 Construcción de modelos y su desempeño en la calibración.

Los resultados mostraron que los modelos generados a partir de la Regresión Ridge, explicaron entre un 77% y un 91% de variabilidad del rendimiento dentro de los ensayos (Cuadro 4). Los valores de coeficiente de determinación ( $R^2$ ) para el rendimiento, fueron mayores en los ensayos con estrés medio ( $R^2 = 88\%$ ) en antesis y estrés severo ( $R^2 = 91\%$ ) en llenado de granos. El mayor  $R^2$  fue obtenido en la condición de ES en llenado de granos. Los valores de RMSE más extremos fueron de 210 y 809  $\text{kg ha}^{-1}$  para ES-LLG y RC-AN, respectivamente. Para el caso de los rRMSE, los mayores valores se obtuvieron en ambas condiciones de estrés (MS y SS) en el estado de llenado de granos, con valores de 14,4 % y

12,7%, respectivamente. Los menores valores de rRMSE se obtuvieron en RC independiente del estado fenológico.

Cuadro 4. Estadísticos más importantes de los modelos multivariados individuales para estimar rendimientos basados en la firma espectral.

<b>Modelo</b>	<b>n</b>	<b>Lambda</b>	<b>R2 (%)</b>	<b>RMSE</b>	<b>rRMSE</b>
<b>Antesis</b>					
RC	397	56.76	80	809	10.2
EM	399	3.83	88	498	10.5
<b>Llenado Granos</b>					
RC	301	3.8	83	725	9.2
EM	399	20.7	77	684	14.4
ES	391	2.1	91	210	12.7

n: número de muestras; lamda: valor de penalización del modelo; R<sup>2</sup>: coeficiente de determinación del modelo; RMSE (kg ha<sup>-1</sup>): raíz cuadrada del error estándar; rRMSE: relación entre el RMSE y el error estándar del rendimiento del modelo.

Además, los datos de reflectancia para cada uno de los estados de desarrollo evaluados fueron unificados para generar modelos combinados (Cuadro 5). Estos modelos combinados tuvieron un R<sup>2</sup> de 90% y 92% en la predicción de rendimiento para antesis y llenado de granos, respectivamente. Posteriormente, los coeficientes de regresión de cada uno de los modelos combinados fueron utilizados para predecir el rendimiento de los distintos ambientes desde donde fueron generados (Figura 5). La validación efectuada sobre los ambientes tuvo un coeficiente de determinación de 81% para RC y EM en estado de antesis. En la etapa de llenado de granos, los R<sup>2</sup> fueron de 77% y 76% para RC y EM, respectivamente. Sin embargo, para el ambiente de ES, la predicción del modelo general no fue significativa, siendo su valor de correlación de 3%.

Cuadro 5. Estadísticos más importantes de los modelos multivariados combinados para estimar rendimientos basados en la firma espectral.

<b>Modelo</b>	<b>n</b>	<b>Lambda</b>	<b>R2 (%)</b>	<b>RMSE</b>	<b>rRMSE</b>
<b>Antesis</b>					
RC-EM	796	4,1	90	711	11,2
<b>Llenado Granos</b>					
RC-EM-ES	1091	1,1	92	760	16,8

n: número de muestras; lamda: valor de penalización del modelo; R<sup>2</sup>: coeficiente de determinación del modelo; RMSE (kg ha<sup>-1</sup>): raíz cuadrada del error estándar; rRMSE: relación entre el RMSE y el error estándar del rendimiento del modelo.

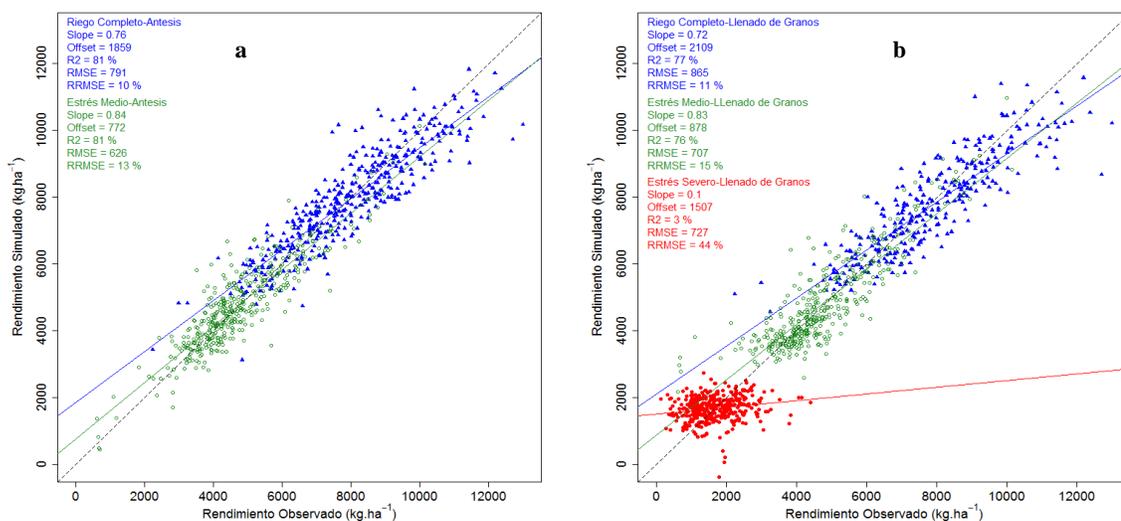


Figura 5. Validación del rendimiento observado ( $\text{kg ha}^{-1}$ ) utilizando los coeficientes de los modelos combinados para los estados fenológicos de antesis (a) y llenado de grano (b).  $R^2$ : coeficiente de determinación. Puntos rojos corresponden a ES, puntos verdes a EM y puntos azules a RC.

Posteriormente, se evaluó la robustez de los modelos generados para cada ambiente y estado fenológico, aplicando cada uno de ellos en las otras condiciones y estados (Cuadro 6). Se observó que tanto la condición ambiental como el estado de desarrollo, mostraron diferencias en la capacidad de predecir el rendimiento. En general, gran parte de los modelos lograron una acertada predicción del rendimiento en otras condiciones ambientales. La mayor correlación fue encontrada para el modelo de ES-LLG aplicado en la condición de EM-LLG, en cambio el menor valor de correlación fue para el modelo EM-LLG aplicado en RC-AN. Se observó que modelos generados en antesis, en general tienen una mayor capacidad de predecir el rendimiento en comparación con los modelos generados en llenado de grano. Además, ambientes de rendimiento bajo y medio muestran una mejor correlación entre los rendimientos observados y los predichos.

Cuadro 6. Coeficientes de determinación de modelos aplicados en diferentes ambientes. Coeficientes de regresión generados para cada ambiente se utilizaron para las predicciones de rendimiento.

	RC-AN		EM-AN		RC-LLG		EM-LLG		ES-LLG	
	R <sup>2</sup>	rRMSE (%)								
<b>RC-AN en (*)</b>			0,59 ***	53	0,31 ***	19	0,48 ***	54	0,18 ***	132
<b>EM-AN en (*)</b>	0,44 ***	55			0,31 ***	54	0,58 ***	19	0,46 ***	99
<b>RC-LLG en (*)</b>	0,45 ***	22	0,21 ***	54			0,42 ***	54	0,50 ***	136
<b>EM-LLG en (*)</b>	0,00 ns	65	0,03 **	43	0,10 ***	62			0,59 ***	104
<b>ES-LLG en (*)</b>	0,21 ***	137	0,18 ***	107	0,06 **	136	0,61 ***	102		

p < 0,05 \*; p < 0,01 \*\*; p < 0,001 \*\*\*; ns = no significativo

(\*) Coeficientes de regresión aplicados en los otros ambientes en diferentes estados fenológicos

Sin embargo, aún cuando los valores de coeficiente de correlación tienden a ser altos para la mayoría de los casos, el valor calculado de rRMSE para estos modelos, fue muy superior a los encontrados tanto en los modelos individuales como combinados, generando un modelo de regresión con pendientes variables. El modelo ES-LLG mostró los valores de rRMSE más altos en todos los ambientes donde se aplicó y además, en esta condición se encontraron los mayores valores de rRMSE cuando se les aplicaron los modelos de otros ambientes.

## 8 Discusión

### 8.1 Reflectancia de la canopia en condiciones contrastantes y su relación con el rendimiento.

Los valores de reflectancia medidos mediante espectroradiometría de campo para las longitudes de onda comprendidas entre los 400 y 2500 nm en los 368 genotipos en los diversos ambientes y estados fenológicos fueron similares a los señalados en trigo y cebada para condiciones ambientales con y sin presencia de estrés considerando diferentes estados de desarrollo (Serrano *et al.*, 1999; Peñuelas *et al.*, 1999). En la zona del espectro visible, asociada al contenido de antocianos, carotenoides y clorofila en diferentes especies (Gitelson *et al.*, 2009; Hatfield *et al.*, 2008) se ha observado una menor reflectancia correlacionada con un mayor rendimiento. Esto fue observado por Serrano *et al.* (2000a) y Filella *et al.* (1995), donde mayores dosis de N se asociaron a menor reflectancia en la zona cercana al rojo. En la zona del NIR, una mayor reflectancia se asoció a un mayor rendimiento, lo cual concuerda con Peñuelas *et al.* (1996), donde encontraron que genotipos con mayor área foliar aumentaban su reflectancia en el NIR, contrario a genotipos sometidos a un déficit nutricional. Se ha visto que el nivel de reflectancia en esta zona está altamente relacionado con variables asociadas a biomasa verde, índice de área foliar y cobertura de hojas (Peñuelas y Filella, 1998).

Al comparar la información de los genotipos contrastantes con las correlaciones generales, se observó una relación coherente entre ambas situaciones. Genotipos con menor rendimiento, en general reflejaron una mayor cantidad de radiación en las longitudes de onda comprendidas entre los 400-750 nm, lo que concuerda con Peñuelas *et al.* (1993b) donde una menor reflectancia está asociada a un mayor contenido de clorofila a y con Zhao *et al.* (2003) en un experimento de maíz en el cual déficit de nitrógeno aumento la reflectancia entre los 550 y 710 nm. En la zona del NIR (800-1300 nm), genotipos de mayor rendimiento mostraron en todos los ambientes una mayor reflectancia, lo que estaría asociado con valores mayores de caracteres como índice de área foliar y biomasa (Peñuelas *et al.*, 1996; Peñuelas *et al.*, 1997a). Entre los 859-900 nm, la menor reflectancia encontrada para el estrés intermedio está relacionada con el contenido hídrico del dosel (Peñuelas *et al.*, 1993a). Para la región entre los 1300 y 2500 nm, la cual está asociada al contenido hídrico, genotipos de bajo rendimiento mostraron una mayor reflectancia, siendo en condición de estrés donde aumentaron estas diferencias. Seelig *et al.* (2008) señala que las longitudes 1300 y 1450 nm, exhibían una correlación significativa con el contenido de agua de la hojas, baja variabilidad y alta sensibilidad.

### 8.2 Reflectancia en hojas asociados a los coeficientes de los modelos.

En los modelos, los mayores coeficientes de regresión generados por la regresión multivariada para cada longitud, se encontraron en zonas relacionadas con el contenido de clorofila (680 y 550 nm) y carotenoides (480 nm) (Zhao *et al.*, 2003), índice de área foliar y biomasa (680-980 nm) (Peñuelas *et al.*, 1997a), contenido de agua en NIR (900-970 nm) (Peñuelas *et al.*, 1997b) y SWIR (1300-1450 nm) (Seelig *et al.*, 2008). En antesis, tanto

riego completo y estrés medio mostraron valores negativos, los cuales cambiaron a positivos en llenado de granos en la zona de los 680 nm. En cambio, en los 550 nm, los valores fueron contrarios entre los ambientes de riego completo y estrés medio para el mismo estado fenológico. Esto concuerda con Peñuelas y Filella (1998) y Zhao *et al.* (2003), quienes señalan que estas zonas pueden detectar cambios en los contenidos de clorofila de las plantas. En la sección de los 750-800 nm, durante antesis los valores positivos de los coeficientes en RC-AN y EM-AN cambian a negativos en llenado de grano, donde ES también presenta el mismo signo. Esta zona, está relacionada con el contenido de los pigmentos cafés (Peñuelas y Filella, 1998) por lo que aumentos de estos compuestos entre los estados pueden ser discriminados por el modelo. En la región del NIR, cambios en la reflectancia relacionados al contenido de nitrógeno y biomasa aérea en maíz (Osborne *et al.*, 2002) están presentes en los coeficientes de regresión. Durante antesis, los valores positivos cercanos a los 800 nm pasan a negativos cerca de los 900 nm en RC y en menor medida en EM, lo cual es inverso a lo encontrado en llenado de grano en las dos condiciones de estrés hídricas y en menor medida en la condición de riego. Estas variaciones en la magnitud de los coeficientes podrían estar dando cuenta de cambios en el dosel, ya que esta zona ha sido relacionada con diferencias en la biomasa de la canopia entre antesis y llenado de granos Serrano *et al.* (2000a) y Filella *et al.* (1995). En el caso de las longitudes del NIR asociadas al contenido de agua en la canopia (Peñuelas *et al.*, 1997b), durante antesis tanto RC como EM mostraron valores cercanos a 0 mientras que en llenado de granos, EM, ES y en menor medida RC, muestran valores positivos y elevados. Peñuelas *et al.* (1997b), señala que variaciones entre los 900 y 970 nm, están asociadas al contenido relativo de agua en los tejidos vegetales. Además, cualquier tipo de estrés durante llenado de granos, se verá reflejado en el rendimiento (Acevedo *et al.*, 1999). En la zona del espectro entre los 1100 a 1140 nm, asociada con el contenido y la absorbancia del agua, RC y EM en antesis muestran valores negativos los que cambian a positivo en llenado de grano a excepción de ES, sin embargo, entre los 1240 y 1260 nm, todos los valores fueron negativos. Sims y Gamon (2003), señalaron que estas zonas están correlacionadas directamente con el contenido de agua de plantas tanto en estado natural como en ensayos experimentales.

De este modo, genotipo con baja reflectancia en el VIS (400-700 nm), alta reflectancia en el NIR (750-1100) y baja reflectancia en el SWIR (1300-2400), zonas en las cuales se ha asociado a una alta capacidad fotosintética, biomasa y contenido de agua, respectivamente, tenderán a tener un mayor rendimiento que genotipos con características contrastantes. En trigo, varios son los estudios que han asociado el rendimiento con varios de los índices generados a partir de estas zonas de la firma espectral (Aparicio *et al.*, 2002; Aparicio *et al.*, 2000; Royo *et al.*, 2003).

### **8.3 IRes v/s modelos multivariados para la estimación del rendimiento.**

En relación a los índices espectrales, el rango de los coeficientes de determinación fue entre 0,0% y 72,4% siendo WI, el que mostro las mejores correlaciones con el rendimiento en ambos estados fenológicos. Este índice está asociado al contenido hídrico, siendo esta variable la que estaría en mayor medida influyendo en las variaciones del rendimiento. Los otros índices, en general, fueron muy dependientes del medio. Resultados obtenidos por

Royo *et al.* (2003) en trigo, mostraron que los índices WI, SR y los 680 nm, medidos en llenado de granos, mostraron una mayor correlación con el rendimiento. Sin embargo, también encontraron que las asociaciones eran extremadamente dependientes del ambiente.

Los modelos multivariados, aun cuando son aproximaciones empíricas, mostraron buenas correlaciones con el rendimiento e integraron la variada información proveniente desde diferentes zonas de la firma espectral, encontrándose asociaciones similares a otros estudios que determinan el rendimiento (Babar *et al.*, 2006; Gutierrez *et al.*, 2010). Durante antesis, el mejor modelo fue EM, lo que se puede deber a que bajo esta condición se logra expresar de mejor manera la variabilidad fisiológica entre los genotipos, en relación a la condición de riego, donde la mayoría de los genotipos estaban bajo condiciones de crecimiento óptimas dando respuestas de reflectancia similares. Bajo la condición de estrés medio se apreció de mejor manera la variabilidad de los rendimientos dentro del ensayo (CV = 30,1%), lo cual aumenta la magnitud de variación de los datos, mejorando la capacidad predictiva del modelo (Ferrio *et al.*, 2005).

En llenado de granos, el  $R^2$  más alto fue en ES, lo que se pudo originar por lo observado en la Figura 2, donde existe una alta correlación entre la zona del SWIR (asociadas al contenido de agua) con el rendimiento. Así, en ambientes de sequía terminal genotipos que tengan una buena capacidad hídrica a llenado de granos lograran los mejores rendimientos. Con respecto a los modelos combinados estos mostraron  $R^2$  mayores que los modelos individuales, por lo que la integración de una mayor cantidad de información medida mejoraría la capacidad de predicción. Además, cuando los datos de los modelos combinados se utilizaron para predecir el rendimiento de los ensayos desde los cuales fueron generados, los coeficientes de determinación en general se mantuvieron altos. Para el caso de las mediciones realizadas en antesis, los valores de  $R^2$  para los modelos combinados bajaron un 8% en la capacidad de predecir el rendimiento en comparación a los modelos individuales. Esta leve disminución de la estimación se pudo deber a una mayor cantidad de información dentro del modelo, tanto en número de ambientes (3) como en número de genotipos evaluados, (368), lo que representa una cifra importante para este tipo de estudios. En el caso de llenado de granos, se observó una disminución de los coeficientes de determinación desde un 91% hasta un 76% y 77% para la condición de estrés medio y riego óptimo, respectivamente. Sin embargo, en estrés severo, esta disminución fue mayor, llegando a un 3% de la capacidad de predecir el rendimiento. Esto se pudo deber a que en las condiciones de EM y RC, los principales componentes que determinaron el rendimiento están relacionados con el contenido de clorofila, biomasa e índice de área foliar, en cambio en ambiente con limitaciones severas de agua, lo que más pesa es la capacidad hídrica que tenga la planta hasta el final del periodo (llenado de granos), por lo tanto, el peso asignado a los factores que componen el modelo será distinto. Por lo tanto, aun cuando es posible generar modelos combinados entre diferentes ambientes, no se debe obviar las interacciones generadas entre los genotipos y el ambiente ya que las características que están siendo utilizadas para lograr las predicciones de rendimientos son diferentes entre los ambientes. Sin embargo, al ser un modelo empírico estas diferencias no son consideradas al generar la predicción. Una situación similar fue observada por Weber *et al.* (2012) en maíz, donde al utilizar los coeficientes de regresión de los modelos combinados en los ambientes que lo generaron, encontró una disminución en su capacidad de predicción del rendimiento. Finalmente, los modelos multivariados mostraron una mayor capacidad de predecir el

rendimiento en los diferentes ambientes y estados fenológicos evaluados en comparación con los índices evaluados para este estudio.

#### **8.4 Modelos individuales para la selección por rendimiento en ambientes contrastantes.**

La utilización de los coeficientes de los modelos individuales para la determinación del rendimiento en los otros ensayos generó información complementaria a lo ya encontrado. En este caso el modelo que predijo en promedio mejor los rendimientos en los demás ambientes fue el generado durante anthesis en el ambiente de estrés hídrico medio. Esto se pudo deber en parte, a que en este estado existe una mayor variabilidad en relación al contenido de clorofila, biomasa y contenido de agua junto con una mayor variabilidad en la expresión del rendimiento entre los genotipos evaluados en comparación a los otros ambientes. Sin embargo, los valores de rRMSE fueron para todos los modelos muy superiores a los datos de los modelos individuales. Por lo tanto, una de las principales limitantes que se presenta al usar modelos generados en diferentes condiciones ambientales y en diferentes estados fenológicos es que no pueden ser utilizados sin realizar una detallada calibración de los modelos generando las validaciones correspondientes.

## 9 CONCLUSIONES.

La información generada a partir del uso de la espectroradiometría de campo en diferentes estados fenológicos y condiciones hídricas permite discriminar rendimientos entre diferentes genotipos de trigo harinero.

Dentro de los diferentes índices espectrales evaluados para determinar el rendimiento, el índice que mejor logró realizar una predicción del rendimiento bajo las condiciones de ensayo fue el WI.

Los modelos de regresión multivariados Ridge, fueron más precisos en discriminar los genotipos de acuerdo al rendimiento en comparación a los índices espectrales evaluados. No obstante, tanto los modelos como los índices son dependientes del ambiente donde se realiza la medición.

Los modelos combinados multivariados que utilizaron la información conjunta desde un mismo periodo de desarrollo mejoraron la capacidad de predecir el rendimiento a partir de la información proveniente de la firma espectral.

La utilización de los coeficientes de regresión de los diferentes modelos para la predicción de los rendimientos en otras situaciones, aun cuando mostraron valores significativos en su predicción, fueron muy variables entre las diferentes condiciones.

La utilización de la totalidad de longitudes de onda del espectro de reflectancia de la canopia, para el mismo estado fenológico en diferentes ambientes fue muy superior a la predicción de rendimiento basada en índices espectrales.

## 10 LITERATURA CITADA

Acevedo, E. H.; P. Silva; H. Silva y B. Solar. 1999. Wheat: ecology and physiology of yield determination: Wheat production in Mediterranean environments. Food Products Press. New York. 295-331.

Addink, E. A.; S. M. De Jong y E. J. Pebesma. 2007. The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery. *Photogrammetric Engineering and Remote Sensing*, 73(8): 905.

Aparicio, N.; D. Villegas; J. L. Araus; J. Casadesús y C. Royo. 2002. Relationship between growth traits and spectral vegetation indices in durum wheat. *Crop Science*, 42(5): 1547-1555.

Aparicio, N.; D. Villegas; J. Casadesus; J. L. Araus y C. Royo. 2000. Spectral vegetation indices as nondestructive tools for determining durum wheat yield. *Agronomy Journal*, 92(1): 83-91.

Araus, J. L. 1996. Increasing yield potential in Wheat: Breaking the barriers.: Integrative physiological criteria associated with yield potential. (Eds.) Reynolds, M. P., S. Rajaram y A. McNab. CIMMYT. Mexico, D.F. 150-167.

Araus, J. L.; J. Casadesús y J. Bort. 2001. Application of physiology in wheat breeding: Recent tools for the screening of physiological traits determining yield. (Eds.) Reynolds, M. P., J. I. Ortiz-Monasterio y A. McNab. CIMMYT. Mexico, D.F. 59-77.

Araus, J. L.; G. A. Slafer; M. P. Reynolds y C. Royo. 2002. Plant breeding and drought in C3 cereals: what should we breed for? *Annals of Botany*, 89(7): 925-940.

Babar, M.; M. Reynolds; M. Van Ginkel; A. Klatt; W. Raun y M. Stone. 2006. Spectral reflectance indices as a potential indirect selection criteria for wheat yield under irrigation. *Crop Science*, 46(2): 578-588.

Ball, S. T. y C. F. Konzak. 1993. Relationship between grain yield and remotely-sensed data in wheat breeding experiments. *Plant Breeding*, 110(4): 277-282.

Blum, A. 1988. Plant breeding for stress environments. Ed CRC Press. Boca Raton, Florida

Cai, T.; C. Ju y X. Yang. 2009. Comparison of ridge regression and partial least squares regression for estimating above-ground biomass with Landsat images and terrain data in Mu US Sandy Land, China. *Arid Land Research and Management*, 23(3): 248-261.

Carter, G. A. 1991. Primary and secondary effects of water content on the spectral reflectance of leaves. *American Journal of Botany*: 916-924.

Cho, M. A.; A. Skidmore; F. Corsi; S. E. Van Wieren y I. Sobhan. 2007. Estimation of green grass/herb biomass from airborne hyperspectral imagery using spectral indices and

partial least squares regression. *International Journal of Applied Earth Observation and Geoinformation*, 9(4): 414-424.

Condon, A. G.; R. A. Richards; G. J. Rebetzke y G. D. Farquhar. 2002. Improving intrinsic water-use efficiency and crop yield presented at the 1999 CSSA Symposium on water use efficiency, organized by Div. C-2 chair, Dr. Tom Gerik. *Crop Science*, 42(1): 122-131.

Ferrio, J. P.; D. Villegas; J. Zarco; N. Aparicio; J. L. Araus y C. Royo. 2005. Assessment of durum wheat yield using visible and near-infrared reflectance spectra of canopies. *Field Crops Research*, 94(2-3): 126-148.

Filella, I.; L. Serrano; J. Serra y J. Peñuelas. 1995. Evaluating wheat nitrogen status with canopy reflectance indices and discriminant analysis. *Crop Science*, 35(5): 1400-1405.

Gamon, J. A.; C. B. Field; M. L. Goulden; K. L. Griffin; A. E. Hartley; G. Joel. et al. 1995. Relationships between NDVI, canopy structure and photosynthesis in three californian vegetation types. *Ecological Applications*, 5(1): 28-41.

Gates, D. M.; H. J. Keegan; J. C. Schleter y V. R. Weidner. 1965. Spectral properties of plants. *Applied Optics*, 4(1): 11-20.

Gitelson, A. A.; O. B. Chivkunova y M. N. Merzlyak. 2009. Nondestructive estimation of anthocyanins and chlorophylls in anthocyanic leaves. *American Journal of Botany*, 96(10): 1861-1868.

Gutierrez, M.; M. P. Reynolds; W. R. Raun; M. L. Stone y A. R. Klatt. 2010. Spectral water indices for assessing yield in elite bread wheat genotypes under well-irrigated, water-stressed, and high-temperature conditions. *Crop Science*, 50(1): 197-214.

Hastie, T.; R. Tibshirani; J. Friedman y J. Franklin. 2005. The elements of statistical learning: data mining, inference and prediction. *The Mathematical Intelligencer*, 27(2): 83-85.

Hatfield, J.; A. A. Gitelson; J. S. Schepers y C. Walthall. 2008. Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*, 100(Supplement\_3): S-117-S-131.

Hoerl, A. E. y R. W. Kennard. 1970a. Ridge regression: applications to nonorthogonal problems. *Technometrics*, 12(1): 69-82.

Hoerl, A. E. y R. W. Kennard. 1970b. Ridge regression: biased estimation for nonorthogonal problems. *Technometrics*, 12(1): 55-67.

Jackson, P. A. 2001. Application of physiology in wheat breeding: Directions for physiological research in breeding: Issues from a breeding perspective. (Eds.) Reynolds, M. P., J. I. Ortiz-Monasterio y A. McNab. CIMMYT. Mexico, D.F. 11-16.

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.

Kou, L.; D. Labrie y P. Chylek. 1993. Refractive indices of water and ice in the 0.65- to 2.5- $\mu\text{m}$  spectral range. *Applied Optics*, 32(19): 3531-3540.

Lazaridis, D. C.; J. Verbesselt y A. P. Robinson. 2010. Penalized regression techniques for prediction: a case study for predicting tree mortality using remotely sensed vegetation indices This article is one of a selection of papers from Extending Forest Inventory and Monitoring over Space and Time. *Canadian Journal of Forest Research*, 41(1): 24-34.

Liu, J.; E. Pattey; J. R. Miller; H. McNairn; A. Smith y B. Hu. 2010. Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model. *Remote Sensing of Environment*, 114(6): 1167-1177.

Loss, S. P. y K. H. M. Siddique. 1994. Advances in Agronomy: Morphological and physiological traits associated with wheat yield increases in mediterranean environments (Ed.) Donald, L. Sparks. Academic Press. 229-276.

Miller, A. J. 1984. Selection of subsets of regression variables. *Journal of the Royal Statistical Society. Series A (General)*, 147(3): 389-425.

Monneveux, P.; C. Sanchez y A. Tiessen. 2008. Future progress in drought tolerance in maize needs new secondary traits and cross combinations. *The Journal of Agricultural Science*, 146(03): 287-300.

Osborne, S.; J. S. Schepers; D. Francis y M. R. Schlemmer. 2002. Use of spectral radiance to estimate in-season biomass and grain yield in nitrogen-and water-stressed corn. *Crop Science*, 42(1): 165-171.

Peñuelas, J. y I. Filella. 1998. Visible and near-infrared reflectance techniques for diagnosing plant physiological status. *Trends in Plant Science*, 3(4): 151-156.

Peñuelas, J.; I. Filella; C. Biel; L. Serrano y R. Savé. 1993a. 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.; I. Filella; L. Serrano y R. Savé. 1996. Cell wall elasticity and Water Index (R970 nm/R900 nm) in wheat under different nitrogen availabilities. *International Journal of Remote Sensing*, 17(2): 373-382.

Peñuelas, J.; J. A. Gamon; K. L. Griffin y C. B. Field. 1993b. Assessing community type, plant biomass, pigment composition, and photosynthetic efficiency of aquatic vegetation from spectral reflectance. *Remote Sensing of Environment*, 46(2): 110-118.

Peñuelas, J. y Y. Inoue. 1999. Reflectance indices indicative of changes in water and pigment contents of peanut and wheat leaves. *Photosynthetica*, 36(3): 355-360.

Peñuelas, J.; R. Isla; I. Filella y J. L. Araus. 1997a. Visible and near-infrared reflectance assessment of salinity effects on barley. *Crop Science*, 37(1): 198-202.

Peñuelas, J.; J. Pinol; R. Ogaya y I. Filella. 1997b. Estimation of plant water concentration by the reflectance Water Index WI (R900/R970). *International Journal of Remote Sensing*, 18(13): 2869-2875.

R\_Core\_Team. 2012. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org>.

Randolph, T. W. 2006. Scale-based normalization of spectral data. *Cancer Biomarkers*, 2(3): 135-144.

Rebetzke, G. J.; A. G. Condon; R. A. Richards y G. D. Farquhar. 2002. Selection for reduced carbon isotope discrimination increases aerial biomass and grain yield of rainfed bread wheat. *Crop Science*, 42(3): 739-745.

Richards, R. 1982. Breeding and selecting for drought resistance in wheat. *Drought resistance in crops with emphasis on rice*: 303-316.

Richards, R. A. 1996. Defining selection criteria to improve yield under drought. *Plant Growth Regulation*, 20(2): 157-166.

Royo, C.; N. Aparicio; D. Villegas; J. Casadesus; P. Monneveux y J. L. Araus. 2003. Usefulness of spectral reflectance indices as durum wheat yield predictors under contrasting Mediterranean conditions. *International Journal of Remote Sensing*, 24(22): 4403-4419.

Seelig, H. D.; A. Hoehn; L. S. Stodieck; D. M. Klaus; W. W. Adams Iii y W. J. Emery. 2008. The assessment of leaf water content using leaf reflectance ratios in the visible, near-, and short-wave-infrared. *International Journal of Remote Sensing*, 29(13): 3701-3713.

Serrano, L.; I. Filella y J. Peñuelas. 2000a. Remote Sensing of Biomass and Yield of Winter Wheat under Different Nitrogen Supplies. *Crop Science*, 40(3): 723-731.

Serrano, L.; S. L. Ustin; D. A. Roberts; J. A. Gamon y J. Peñuelas. 2000b. Deriving water content of chaparral vegetation from AVIRIS data. *Remote Sensing of Environment*, 74(3): 570-581.

Sims, D. A. y J. A. Gamon. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81(2-3): 337-354.

Sims, D. A. y J. A. Gamon. 2003. Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water and chlorophyll absorption features. *Remote Sensing of Environment*, 84(4): 526-537.

Venables, W. N. y B. D. Ripley. 2002. Modern Applied Statistics with

S. Fourth Edition. Springer. New York. ISBN 0-387-95457-0.

Weber, V. S.; J. L. Araus; J. E. Cairns; C. Sanchez; A. E. Melchinger y E. Orsini. 2012. Prediction of grain yield using reflectance spectra of canopy and leaves in maize plants grown under different water regimes. *Field Crops Research*, 128(0): 82-90.

Zhao, D.; K. Raja Reddy; V. G. Kakani; J. J. Read y G. A. Carter. 2003. Corn (*Zea mays* L.) growth, leaf pigment concentration, photosynthesis and leaf hyperspectral reflectance properties as affected by nitrogen supply. *Plant and Soil*, 257(1): 205-218.