



*Instituto de  
Altos Estudios Espaciales  
Mario Gulich*



***GENERACIÓN DE MAPAS DE TEMPERATURA RADIATIVA DE  
SUPERFICIE UTILIZANDO DATOS DE BAJA RESOLUCIÓN  
ESPACIAL MEDIANTE TÉCNICAS DE REMUESTREO.***

Tesis para acceder al título de:

***MAGISTER EN APLICACIONES ESPACIALES EN ALERTA Y RESPUESTA TEMPRANA A  
EMERGENCIAS***

***Lic. Martín Ignacio Bayala***

*Director:*

*Dr. Raúl Eduardo Rivas.*

*Instituto de Hidrología de Llanuras "Eduardo Usunoff" (UNCPBA-CIC), Buenos Aires, Argentina.*

*Co-director:*

*Dr. Marcelo Scavuzzo.*

*Instituto Gulich - CONAE, Córdoba, Argentina.*

## *DECLARACIÓN*

---

“Declaro que la información y material incluido en esta tesis es producto de mi propio trabajo y que el material no fue presentado parcial o totalmente en esta u otras instituciones”.

Para consultas con fines académicos se podrá solicitar permiso al autor o Director de la “Maestría en Aplicaciones Espaciales en Alerta y Respuesta Temprana a Emergencias”. Instituto Gulich, Comisión Nacional de Actividades Espaciales (CONAE), Ruta C45, km 7, Falda del Cañete, Córdoba, Argentina.

*E-mail:* [martinbayala@gmail.com](mailto:martinbayala@gmail.com)

## *DEDICATORIA*

---

Esta tesis está dedicada a mis padres, Jorge y Luciana a quienes les debo todo.

A Betiana por brindarme su apoyo y amor.

A mis hermanos Germán, Jorgelina, Emmanuel, María Paz y Juan María.

A mis sobrinas Valentina, Aimará y Genara.

A la memoria de mis abuelos Antonio, Celia y María Estela.

Así como a la de Ricardo A. Bertolami.

## *AGRADECIMIENTOS*

---

Agradezco al Dr. Raúl Eduardo Rivas por haberme recomendado como postulante a la beca de maestría en el Instituto de Altos Estudios Espaciales “Dr. Mario Gulich” y haber aceptado la dirección de mi tesis, por su permanente ayuda y disposición en cada momento del proceso de tesis. El Dr. Rivas tiene experiencia de trabajo en Hidrología y Teledetección desde hace más de 15 años. En el transcurso de su formación profesional ha logrado con éxito el títulos de Licenciado en Geología (Universidad Nacional de La Pampa, 1993), Especialista en Teledetección (Universidad de Paris VI, 1998) y Magíster (Universidad de Valencia, 2003) y doctor en Física (Universidad de Valencia, 2004). Actualmente se desempeña como vicedirector del Instituto de Hidrología de Llanuras “Dr. Eduardo Usunoff”, investigador adjunto de la Comisión de Investigaciones Científicas de Buenos Aires (CIC) y es profesor Adjunto en la Facultad de Agronomía (Universidad Nacional del Centro de la Provincia de Buenos Aires). Su experiencia en teledetección está documentada por su participación en 19 proyectos de investigación de carácter nacional (CONAE) e internacional (Agencia Espacial Europea-ESA). Posee en su haber 8 libros editados, 15 cursos de posgrado, 25 publicaciones en revistas, 90 publicaciones en congresos en la línea de investigación centrada en el infrarrojo térmico y balances de energía.

Al Dr. Marcelo Scavuzzo por la ayuda brindada en el proceso de tesis desempeñando el rol de codirector de tesis. El Dr. Scavuzzo se ha desempeñado como investigador y docente en la Facultad de Matemática, Astronomía y Física (Universidad Nacional de Córdoba - UNC) en el área de desarrollo de tecnología espacial desde hace 23 años. Actualmente se desempeña como Director de la Maestría en Aplicaciones Espaciales en Alerta y Respuesta Temprana a Emergencias y como jefe de la unidad de consultoría en Aplicaciones de Alerta y Respuesta Temprana a Emergencias Ambientales, Instituto de Altos Estudios Espaciales “Dr. Mario Gulich”, Comisión Nacional de Actividades Espaciales, CONAE. Consta de una amplia formación profesional, dentro de sus logros más significativos se encuentra el título de Licenciado en Física (UNC, 1989), Doctor en Física (UNC, 1994) y Pos-Doctorado (Laboratorio de Meteorología Dinámica, Ecole Polytechnique, Paris). Colaboró en un vasto número de proyectos de investigación nacional e internacional relacionado con el censado remoto y modelado numérico. Además, ha dictado más de 15 cursos de posgrado y participado de más de 170 publicaciones científicas.

A la Comisión de Actividades Espaciales por haberme dado la posibilidad de formarme en aplicaciones espaciales y teledetección. Como así también a todos los profesores de los diferentes cursos de maestría, quienes aportaron su conocimiento y me apoyaron en todo momento.

Expreso mi agradecimiento por su colaboración en este trabajo al Ing. Ezequiel González Rial, por su ayuda en programación en el lenguaje IDL y software estadístico R. A la Dra. Ximena Porcasi por su apoyo en estadística.

Al Lic. Facundo Carmona y a la Lic. Dora Ocampo por su ayuda en la estimación de la temperatura de superficie y material bibliográfico cedido.

Finalmente, a mis familiares y amigos por brindarme su apoyo incondicional.

## *ÍNDICE*

RESUMEN.....	14
ABSTRACT .....	15
PARTE I.....	16
INTRODUCCIÓN Y FUNDAMENTACION TEÓRICA .....	16
Capítulo I. INTRODUCCIÓN .....	17
Capítulo 2. FUNDAMENTACIÓN TEÓRICA .....	24
2.1. ANTECEDENTES .....	24
2.2. FUNDAMENTOS FÍSICOS .....	27
2.3. TEMPERATURA DE SUPERFICIE .....	30
2.4. CONTEXTO NDVI - $T_s$ .....	33
2.5. REMUESTREO DE DATOS TÉRMICOS.....	37
2.6. ÍNDICES DE ESTRÉS HÍDRICO .....	40
PARTE II.....	43
MATERIALES Y MÉTODO .....	43
Capítulo 3. CARACTERIZACIÓN DEL ÁREA DE ESTUDIO y DATOS UTILIZADOS .....	44
Capítulo 4. METODOLOGÍA .....	48
4.1. MODELOS DE REMUESTREO DE DATOS TÉRMICOS .....	48
4.1.1. MODELO FCLS (Función Cuadrática del Límite Seco). .....	48
4.1.2. MODELO DE DIFERENCIA DE LÍMITES. ....	50
4.1.3. MODELOS BASADOS EN ÍNDICES DE ESTRÉS HÍDRICO .....	50

4.2. EVALUACIÓN ESTADÍSTICA DE LOS MODELOS PLANTEADOS.....	53
4.3. PROCESAMIENTO DE IMÁGENES DE SATELITE.....	56
4.3.1. IMAGEN LANDSAT.....	56
4.3.1.1. CORRECCIÓN RADIOMÉTRICA.....	56
4.3.1.2. CORRECCIÓN ATMOSFÉRICA.....	57
4.3.1.3. ESTIMACION DE $T_s$ USANDO ALGORITMO MONOCANAL.....	60
4.3.2. IMÁGENES MODIS TERRA.....	61
4.3.2.1. CORRECCIÓN GEOMÉTRICA.....	62
4.3.2.2. CORRECCIÓN RADIOMÉTRICA.....	62
4.3.2.3. CORRECCIÓN ATMOSFÉRICA.....	62
4.3.2.4. ESTIMACIÓN DE $T_s$ USANDO ALGORITMO SPLIT WINDOW.....	63
4.3.2.5. GENERACIÓN DE MÁSCARA DE NUBES.....	64
PARTE III.....	66
RESULTADOS Y DISCUSIÓN.....	66
Capítulo V - RESULTADOS OBTENIDOS A PARTIR DE IMÁGENES LANDSAT TM.....	67
5.3. ANÁLISIS DE MODELOS POR TIPO DE COBERTURA.....	81
Capítulo VI - RESULTADOS OBTENIDOS A PARTIR DE IMÁGENES MODIS.....	85
6.1. EVALUACIÓN GLOBAL DE LOS MODELOS.....	85
6.2. EVALUACIÓN DE LOS MODELOS EN UN ÁREA CON ALTA PROPORCIÓN DE VEGETACIÓN.....	93
6.3. EVALUACIÓN DE LOS MODELOS EN UN ÁREA CON BAJA PROPORCIÓN DE VEGETACIÓN.....	98

Capítulo VII - VALIDACIÓN DE MODELOS.....	102
PARTE IV.....	105
CONSIDERACIONES FINALES y RECOMENDACIONES.....	105
CONSIDERACIONES FINALES.....	106
RECOMENDACIONES.....	108
REFERENCIAS BIBLIOGRÁFICAS.....	109
ANEXOS.....	122

## ÍNDICE DE FIGURAS

Figura 2.1: Curva de emitancia radiativa de un cuerpo negro a distintas temperaturas (Chuvieco, 2008).....	29
Figura 2.2: Espacio NDVI- $T_s$ modificado de Girolimetto et al. (2007).....	36
Figura 2.3: Esquema general del método de remuestreo de datos térmicos propuesto por Kustas (2003).....	38
Figura 2.4: a) Respuesta del NDII y NDWI en vegetación con estado hídrico óptimo, b) Respuesta espectral de la vegetación senescente bajo estrés hídrico (Extraído de Ormeño, 2006).....	42
Figura 3.1: Ubicación relativa de la EBE instalada en la parcela de soja en el establecimiento agrícola Laura Laufú (37° 14' S, 59° 34' O) y estación con sensores. La imagen central muestra un recorte de la imagen captada por el sensor TM del día 23/02/2010 (RGB 247).....	46
Figura 3.2: Fuente de calibrado y sensor Raytex en etapa de intercalibrado. ....	47
Figura 4.1: Identificación de límites en el espacio NDVI - $T_s$ .....	48
Figura 4.2: a) $T_s$ vs. NDVI, b) $T_s$ vs. NDWI.....	51
Figura 4.3: Esquema metodológico de remuestreo en imágenes MODIS. ....	52
Figura 4.4: Radiancia recibida por el sensor remoto e interacciones atmósfera - energía EM (modificado de Jensen, 1996).....	58
Figura 4.5: a) Histograma de reflectividad de la banda 26 ( $\rho_{26}$ ), b) máscara resultante de la extracción de datos por medio del producto MOD03 y del histograma de $\rho_{26}$ .....	65
Figura 5.1: Comparación entre pendiente y ordenada al origen a diferentes resoluciones espaciales. a) Pendientes de funciones con respecto a la resolución espacial, b) Ordenada al origen de funciones con respecto a la resolución espacial.....	69
Figura 5.2: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados: $T_s$ HARP, $T_s$ *FCLS, $T_s$ *Dif. de límites(FC_dif), $T_s$ *SWIharp, $T_s$ *NDIIharp, $T_s$ *GVMIharp. ....	70

Figura 5.3: Modelos de ajuste lineal entre la $T_s$ Landsat 5 TM vs. $T_s$ estimada por los modelos a 720 m. a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs. $T_s$ *Dif. Límites, d) $T_s$ vs. $T_s$ *SWIharp, e) $T_s$ vs. $T_s$ *NDIharp, f) $T_s$ vs. $T_s$ * GVMiharp. ....	71
Figura 5.4: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados: $T_s$ HARP, $T_s$ *FCLS, $T_s$ * Dif. de límites (FC_dif), $T_s$ *SWIharp, $T_s$ *NDIharp, $T_s$ *GVMiharp.....	73
Figura 5.5: Modelos de ajuste lineal entre la $T_s$ Landsat TM vs. $T_s$ estimada por los modelos a 240 m, a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs. $T_s$ *Dif. Límites, d) $T_s$ vs. $T_s$ *SWIharp, e) $T_s$ vs. $T_s$ *NDIharp, f) $T_s$ vs. $T_s$ *GVMiharp. ....	74
Figura 5.6: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados: $T_s$ HARP, $T_s$ *FCLS, $T_s$ * Dif. de límites (FC_dif), $T_s$ *SWIharp, $T_s$ *NDIharp, $T_s$ *GVMiharp.....	75
Figura 5.7: Modelos de ajuste lineal entre la $T_s$ Landsat TM vs. $T_s$ estimada por modelos a 120 m. a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs. $T_s$ * Dif. Límites, d) $T_s$ vs. $T_s$ *SWIharp, e) $T_s$ vs. $T_s$ *NDIharp, f) $T_s$ vs. $T_s$ *GVMiharp. ....	76
Figura 5.8: Resultados de estadísticos a diferentes resoluciones espaciales de la imagen Landsat TM. a) $R^2$ , b) RMSE (K), c) RE (K) d) ME (K). ....	77
Figura 5.9: Semivariograma de imagen $T_s$ Landsat TM (30m).a) Sentido Este - Oeste, b) Sentido Norte - Sur. ....	78
Figura 5.10: Q - Q plot de la $T_s$ observada con respecto al valor normal esperado. ....	79
Figura 5.11: Boxplot de los datos térmicos obserbados ( $T_s$ ) y estimados a 30 m de resolución espacial: $T_s$ HARP, $T_s$ *FCLS, $T_s$ * Dif. de límites (FC_dif), $T_s$ *SWIharp, $T_s$ *NDIharp, $T_s$ *GVMiharp.....	80
Figura 5.12: Modelos de ajuste lineal entre la $T_s$ Landsat TM vs. $T_s$ estimada por modelos a 30 m. a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs. $T_s$ *Dif. Límites, d) $T_s$ vs. $T_s$ *SWIharp, e) $T_s$ vs. $T_s$ *NDIharp, f) $T_s$ vs. $T_s$ *GVMiharp. ....	81
Figura 5.13: Clasificación ISODATA para la imagen Landsat TM del 23/02/2010. ....	82
Figura 5.14:a) $R^2$ , b) Error Residual Estándar de modelos de remuestreo por clases.....	83

Figura 5.15: a) RMSE, c) RE, d) $RMSE/\sigma$ , e) ME de modelos de remuestreo en función de las clases identificadas en la imagen Landsat TM del 23/02/2010 a 30 m de resolución espacial. ....	84
Figura 6.1: Funciones utilizadas en el método para remuestrear datos térmicos a partir de la imagen de $T_s$ MODIS-Terra remuestreada a 4 km. a) Modelo de ajuste lineal del espacio NDVI- $T_s$ , b) Ajuste cuadrático (límite seco), c) Ajuste lineal (límite húmedo). ....	85
Figura 6.2: Histogramas de frecuencias para los datos observados y estimados para los diferentes métodos. a) $T_s$ obserbada , b) $T_s$ HARP, c) $T_s$ *FCLS, d) $T_s$ *Dif. Límites, e) $T_s$ * NDWIharp, f) $T_s$ *NDIIharp, g) $T_s$ *SWIharp h) $T_s$ *GVMiharp.).....	86
Figura 6.3: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados por los modelos: $T_s$ HARP, $T_s$ *FCLS, $T_s$ * Dif. de límites (FC_dif), $T_s$ *NDWIharp, $T_s$ *NDIIharp, $T_s$ *SWIharp, $T_s$ *GVMiharp. ....	88
Figura 6.4: Modelos de ajuste lineal entre la $T_s$ MODIS-Terra vs. $T_s$ estimada por los modelos a 1km. a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs. $T_s$ *Dif. Límites, d) $T_s$ vs. $T_s$ *NDWIharp e) $T_s$ vs. $T_s$ *NDIIharp, f) $T_s$ vs. $T_s$ *SWIharp g) $T_s$ vs. $T_s$ *GVMiharp. ....	90
Figura 6.5: Mapas de Temperatura de superficie observada. a) imagen MODIS-Terra (1km) y mapas de temperatura estimadas por diferentes modelos (1km), b) $T_s$ HARP, c) $T_s$ *FCLS, d) $T_s$ *Dif. de Límites, e) $T_s$ *NDWIharp, f) $T_s$ *NDIIharp, g) $T_s$ *SWIharp, h) $T_s$ * GVMiharp.....	91
Figura 6.6: Modelos de ajuste lineal entre la $T_s$ MODIS - Terra vs. $T_s$ estimada por los modelos a 1 km, aplicando muestreo aleatorio de datos térmicos para toda la imagen. a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs. $T_s$ *Dif. Límites, d) $T_s$ vs. $T_s$ *NDWIharp e) $T_s$ vs. $T_s$ *NDIIharp, f) $T_s$ vs. $T_s$ *SWIharp g) $T_s$ vs. $T_s$ *GVMiharp. ....	93
Figura 6.7: Mapa de $T_s$ en área con alta cobertura vegetal y mapa de $P_v$ (esquina superior derecha). ....	94
Figura 6.8: Histogramas de frecuencias normalizadas para los datos observados de $T_s$ .....	95
Figura 6.9: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados: $T_s$ HARP, $T_s$ *FCLS, $T_s$ * Dif. de límites (FC_dif), $T_s$ *NDWIharp, $T_s$ *NDIIharp, $T_s$ *SWIharp, $T_s$ *GVMiharp. ....	95
Figura 6.10: Modelos de ajuste lineal entre la $T_s$ MODIS-Terra vs. $T_s$ estimada por los modelos a 1km en el área con alta proporción de vegetación. a) $T_s$ vs. $T_s$ HARP, b) $T_s$ vs. $T_s$ *FCLS, c) $T_s$ vs.	

T <sub>s</sub> *Dif. Límites, d) T <sub>s</sub> vs. T <sub>s</sub> *NDWI <sub>harp</sub> e) T <sub>s</sub> vs. T <sub>s</sub> *NDII <sub>harp</sub> , f) T <sub>s</sub> vs. T <sub>s</sub> *SWI <sub>harp</sub> g) T <sub>s</sub> vs. T <sub>s</sub> *GVM <sub>harp</sub> .....	97
Figura 6.11: Mapa de T <sub>s</sub> en área con baja proporción de vegetación y mapa de P <sub>v</sub> (esquina superior derecha). .....	98
Figura 6.12: Boxplots de los datos térmicos obserbados (T <sub>s</sub> ) y estimados: T <sub>s</sub> HARP, T <sub>s</sub> *FCLS, T <sub>s</sub> *Dif, de límites (FC_dif), T <sub>s</sub> *NDWI <sub>harp</sub> , T <sub>s</sub> *NDII <sub>harp</sub> , T <sub>s</sub> *SWI <sub>harp</sub> , T <sub>s</sub> *GVM <sub>harp</sub> .....	99
Figura 6.13: Histogramas de frecuencias normalizadas para la T <sub>s</sub> en área con baja cobertura vegetal. ....	100
Figura 6.14: Modelos de ajuste lineal entre la T <sub>s</sub> MODIS-Terra vs. T <sub>s</sub> estimada por los modelos a 1km en área con reducida proporción de vegetación (4756 píxeles). a) T <sub>s</sub> vs. T <sub>s</sub> HARP, b) T <sub>s</sub> vs. T <sub>s</sub> *FCLS, c) T <sub>s</sub> vs. T <sub>s</sub> *Dif, Límites, d) T <sub>s</sub> vs. T <sub>s</sub> *NDWI <sub>harp</sub> e) T <sub>s</sub> vs. T <sub>s</sub> *NDII <sub>harp</sub> , f) T <sub>s</sub> vs. T <sub>s</sub> *SWI <sub>harp</sub> g) T <sub>s</sub> vs. T <sub>s</sub> *GVM <sub>harp</sub> . ....	101
Figura 7.1: Variación diaria de la temperatura captada por el sensor CG3 de la CNR 1.....	102
Figura 7.2: Recorte de la imagen captada por el sensor TM del día 11/11/2006 (RGB 432) y transecta de validación (en amarillo). .....	103
Figura 7.3: T <sub>s</sub> (K) en los puntos de la transecta de terreno y los logrados con el método T <sub>s</sub> * Dif. de límites. ....	104

## ÍNDICE DE TABLAS

Tabla 1.1: Sensores de satélites que operan en el espectro visible y térmico. ....	18
Tabla 3.1: Imágenes MODIS y Landsat utilizadas en el trabajo. ....	44
Tabla 5.1: Comparación imagen MODIS Terra y Landsat 5 TM a 960 m de resolución espacial. ....	67
Tabla 5.2: Funciones central, límite seco y húmedo a diferentes resoluciones espaciales. ....	68
Tabla 5.3: Estadísticos comparativos entre la imagen de $T_s$ observada Landsat 5 TM y las estimadas a 720 m de resolución espacial. ....	69
Tabla 5.4: Estadísticos comparativos entre la imagen de $T_s$ observada Landsat 5 TM y las estimadas a 240 m de resolución espacial. ....	72
Tabla 5.5: Estadísticos comparativos entre la imagen de $T_s$ observada Landsat 5 TM y las estimadas a 120 m de resolución espacial. ....	75
Tabla 5.6: Estadísticos comparativos entre la imagen de $T_s$ observada Landsat 5 TM y las estimadas a 30 m de resolución espacial. ....	79
Tabla 6.1: Estadísticos comparativos entre la imagen de $T_s$ observada y las estimadas a 1 km de resolución espacial. ....	87
Tabla 6.2: Estadísticos comparativos entre la imagen de $T_s$ observada y las estimadas a 1 km de resolución espacial. ....	94
Tabla 6.3: Estadísticos comparativos entre la imagen de $T_s$ observada y las estimadas a 1 km de resolución espacial. ....	99

## **RESUMEN**

La temperatura de superficie ( $T_s$ ) es una variable importante dentro del modelado del balance de energía y parámetro fundamental para la estimación de variables hidrológicas como la humedad de suelo y la evapotranspiración. En la actualidad, estudios ambientales que utilizan información proveniente de sensores térmicos aerotransportados para la estimación diaria de la  $T_s$ , sólo han sido posibles a escala regional, limitados principalmente por el tamaño de píxel de la imagen y la frecuencia de revisita de los sensores. En tal sentido, es necesario contar con datos de satélites que permitan la estimación de la  $T_s$  con buena resolución espacio-temporal para la realización de estudios a escala local. En este trabajo se describen las ecuaciones y una metodología de fácil aplicación para estimar la temperatura de superficie ( $T_s$ ) a escala puntual y regional con imágenes MODIS y Landsat TM utilizando principalmente los canales térmicos de los sensores, una precisa estimación de la emisividad y contenido de vapor de agua de la atmósfera. El modelo de Disgregación de Temperatura Radiativa de Superficie (*DisTrad*) posibilitó la manera de generar datos térmicos de alta resolución a partir de datos medidos a baja resolución ( $\geq 1$  km) sobre la base de la relación inversa entre el NDVI a alta resolución y la  $T_s$  a baja resolución.

En esta tesis, se presentan 6 modelos de remuestreo de datos térmicos desarrollados sobre la base metodológica del modelo *DisTrad*, donde se evaluó la eficiencia en la estimación de la  $T_s$  a nivel de subpíxel en un área agrícola heterogénea de la región sub-húmeda pampeana de Argentina. La validación de los datos a nivel de subpíxel se realizó por medio de la asociación de los datos captados por sensores a bordo de plataformas aerotransportadas y medidas puntuales de  $T_s$  provistas por una Estación de Balance de Energía (EBE) y radiómetros portátiles del periodo 2006-2010 en los establecimientos agrícola Laura Leofú (37° 14' S, 59° 34' O) y Tata Dios (37° 06' 45" S y 58° 58' 50" O), ubicados a 25 km de la ciudad de Tandil, Provincia de Buenos Aires, Argentina. Los modelos fueron evaluados usando imágenes Landsat TM con datos agregados desde 960 m a 30 m, resultando la raíz cuadrada del error cuadrático medio (RMSE) menor de 1,5 K. Posteriormente, fueron evaluados usando datos térmicos MODIS Terra de 1 km que fueron agregados a 4 km, con RMSE menor a 1K en promedio. El modelo que presentó la mejor performance con respecto a los datos observados fue el modelo de  $T_s$  diferencia de límites ( $T_s$  Dif. de límites) que hasta el momento no había sido aplicado, indicando resultados estadísticos comparativamente superiores para ambas imágenes y clases analizadas.

**Palabras Clave:** Temperatura de superficie, modelos de remuestreo, validación.

## ***ABSTRACT***

The Land Surface Temperature (LST) is a key parameter in the balance energy model as well as for the retrieve of hydrological parameters like soil moisture and evapotranspiration. Currently, environmental research's have been only possible using remote sensing dataset at regional scale. The major constraints are satellite revisit time and image pixel-size. Therefore, a high spatial resolution LST dataset is needed for local scale studies. This study describes an easy methodology for the retrieval of LST at local and regional scale using MODIS Terra and Landsat Thematic Mapper (TM) dataset, through accurate emissivity and water atmosphere content estimation. The T<sub>s</sub>HARP model provides a possibility to generate fine spatial resolution thermal data from coarse spatial resolution ( $\geq 1$  km) data based on the inverse linear relationship between the normalized difference vegetation index (NDVI) at fine spatial resolution and LST at coarse spatial resolution.

The current study presents six sharpening thermal data models developed on the disaggregation procedure for radiometric surface temperature (*DisTrad*) basis. The sub-pixel accuracy estimation models were assessed over a mixed agricultural landscape in the sub-humid Pampeana region of Argentina. The energy balance station (EBS) database and *in situ* measurements were used for the validation of LST<sub>s</sub> derived from the sharpening models. This measurements were made in the farming sites of Laura Leufú (37° 14' S, 59° 34' O) and Tata Dios (37° 06' 45" S y 58° 58' 50" O) located near the Tandil city, province of Buenos Aires during 2006-2010. Landsat TM thermal dataset (120 m) were assessed to the following spatial resolution: 960 m, 720 m, 240 and 30 m, and root mean square error (RMSE) was less than 1,5 K on average. The models were evaluated also using Moderate Resolution Imaging Spectrometer (MODIS) thermal data (1 km) aggregated to 4 km spatial resolution, which root mean square error (RMSE) of  $< 1$  K on average. The limit difference model has been not implemented until now. This leaded the best statistical performance with respect to the other models tested.

***Keywords:*** Land surface temperature, sharpening models, validation.

***PARTE I***

***INTRODUCCIÓN Y FUNDAMENTACION TEÓRICA***

## **Capítulo I. INTRODUCCIÓN**

El desarrollo de sistemas satelitales para el monitoreo ambiental se presenta como una herramienta excepcional, colaborando con la interpretación y evaluación de variables ambientales (*Chuvienco, 2006*). En este contexto, los sensores a bordo de satélites proporcionan una alta densidad de información espectral, espacial y temporal para el monitoreo de las condiciones hídricas de una región.

La estimación de las condiciones hídricas a partir de datos captados por sensores remotos es una buena alternativa para la obtención de parámetros biofísicos de superficie, los cuales son de gran utilidad en estudios climáticos e hidrológicos a diferentes escalas, permitiendo entender su distribución espacio-temporal del fenómeno (*Sobrino et al., 2000; Rivas et al., 2002; Houspanossian et al., 2008*). Sin embargo, adquiere mayor relevancia la información desde satélite cuando se logra tener datos de la superficie con una buena resolución espacio-temporal (*Rivas et al., 2010*).

La estimación de la temperatura de superficie ( $T_s$ ) diaria es una variable fundamental dentro del modelado del balance de energía, ampliamente utilizada para estimar la humedad de suelo y la evapotranspiración (*Sobrino, 2000; Agam et al., 2007; Rivas et al., 2010*). Por lo tanto, la  $T_s$  es una variable fundamental en el monitoreo ambiental y para estudios agrometeorológicos a diferentes escalas. La precisión requerida para cada aplicación está en función al tamaño de píxel y objeto censado dentro de la escena (*Anderson et al., 2004; Kustas et al., 2004; Agam et al., 2007b; Li et al., 2008; Inamdar et al., 2009*).

La región pampeana argentina se caracteriza por poseer parcelas agrícolas de un tamaño superior a las 30 ha. En tal sentido, se han realizado esfuerzos para estudiar con periodicidad las variables hidrológicas que intervienen en el crecimiento de los cultivos (*Houspanossian et al., 2008, Ocampo et al., 2011; Carmona y Rivas, 2011*). Sin embargo, el tamaño de las parcelas cultivadas son considerablemente más chicas que el tamaño de píxel de los sensores de resolución temporal diaria limitando el uso de la  $T_s$  a estudios de carácter regional. Por lo tanto, es sumamente relevante desarrollar modelos de remuestreo de datos térmicos, que permitan generar una resolución espacial moderada a alta a partir de datos obtenidos por medio de sensores de resolución grosera.

Imágenes de alta resolución espacial ( $\leq 10^2$  metros) provenientes de sensores que operan en el intervalo espectral del infrarrojo térmico (8 - 14  $\mu\text{m}$ ), han sido utilizadas en una gran variedad de

aplicaciones. Estas aplicaciones incluyen la detección de condiciones propicias para incendios forestales (*Di Bella et al., 2008*), evaluación de salud ecosistémica y severidad de sequías (*Ghulam, 2007; Yao, 2011; Gao, 2011*), monitoreo de actividad volcánica (*Carter y Ramsey, 2009; Vaughan, 2010*), estimación de Balance de Energía (BE) terrestre y evapotranspiración (ET) a escala de parcela (*Norman et al., 2003; Rivas y Carmona, 2010*).

En la actualidad operan diferentes tipos de sensores abordo de plataformas satelitales con bandas ubicadas en ventanas del espectro visible y térmico. En la Tabla 1.1 es posible observar la diferencia entre la resolución espacial y temporal del conjunto de datos térmicos, ya sea imágenes de satélites con alta resolución espacial y baja resolución temporal (por ejemplo Landsat 5 Thematic Mapper - TM, Enhanced Thematic Mapper Plus - ETM+, Advanced Space-borne Thermal Emission and Reflection Radiometer - ASTER, Advanced Along - Track Scanning Radiometer - AATSR y New Infrared Sensor Technology - NIRST ) o imágenes con baja resolución espacial y alta resolución temporal (por ejemplo Terra-Aqua Moderate Resolution Imaging Spectrometer - MODIS, Geostacionary Operational Environmental Satellite - GOES, Advance Very High Resolution Radiometer - AVHRR de la National Oceanic and Atmospheric Administration - NOAA).

Sensor	Satélite	Intervalo Espectral VIS/IRC ( $\mu\text{m}$ )	Resolución VIS/IRC (m)	Intervalo Espectral TIR( $\mu\text{m}$ )	Resolución TIR (m)	Tiempo de Revisita (días)	Error (K)
<b>ETM +</b>	Landsat 7	0,45-2,35	30	10,4-12,5	60	16	$\pm 2$
<b>ASTER</b>	Terra	0,52-2,43	15	8,12-11,65	90	Por demanda	$\pm 0,5$
<b>TM</b>	Landsat 5	0,45-2,35	30	10,4-12,5	120	16	$\pm 2$
<b>NIRST</b>	SAC-D	3,8	350	10,85-11,85	350	7	-
<b>MODIS</b>	Terra-Aqua	0,45-2,15	250/1000	8,4-14,38	1000	1-2	$\pm 0,5 - 1$
<b>AVHRR</b>	NOAA	0,58-3,9	1000	10,3-12,5	1000	2	$\pm 1 - 1,5$
<b>AATSR</b>	ENVISAT	0,86-3,93	1000	10,4-12,5	1000	35	$\pm 1$
<b>GOES</b>	GOES	0,53-7,33	1000-4000	10,21-12,47	4000	15 min	$\pm 1$

Tabla 1.1: Sensores de satélites que operan en el espectro visible y térmico.

Por otra parte, una correcta estimación de la temperatura de superficie requiere la precisa corrección de efectos atmosféricos, angulares y de emisividad de la superficie. Los efectos atmosféricos pueden ser corregidos mediante los valores de contenido de vapor de agua en la atmósfera ( $W$ ). Sin embargo, las recientes aplicaciones para estimar la emisividad ( $\epsilon$ ) de la superficie terrestre se centran en el uso de bandas ubicadas en el intervalo del espectro visible a través del porcentaje de

vegetación ( $P_v$ ) (*Valor y Caselles, 1996; Rivas y Caselles, 2004, Rivas et al, 2010*) y en la actualidad a partir de datos de sensores hiperespectrales (*Atitar et al., 2008; Sobrino et al., 2009*). En tal sentido, es necesario contar con parámetros de entrada al modelo de  $T_s$  que tengan la misma resolución espacial.

Existen en la actualidad algoritmos para la estimación de la  $T_s$  basados en el principio de absorción diferencial de la radiación por la atmósfera en diferentes canales del espectro electromagnético que permite corregir la temperatura de brillo o a tope de la atmósfera (TOA). El uso de un algoritmo determinado para la estimación de  $T_s$  depende principalmente del tipo de imagen de satélite utilizada. En tal aspecto, para imágenes que poseen sólo un canal térmico son utilizados algoritmos de  $T_s$  denominados monocanal. Por otra parte, para imágenes que poseen varios canales en el intervalo de espectro electromagnético se utilizan algoritmos conocidos con el nombre *Split Window*.

A escala mundial, diversos autores han trabajado en el desarrollo de modelos que permitan estimar la  $T_s$  obtenida a partir de diferentes sensores activos y pasivos sobre diversas extensiones territoriales, ajustándolos a las características de interés de su región de estudio. (*Prata, 1993, Coll y Caselles, 1997; Coll, Caselles y Rivas, 2005; Galve y Coll, 2008; Jimenez Muñoz y Sobrino, 2003; Huete, 2002; Jimenez Muñoz y Sobrino, 2009; Sobrino y Soria, 2002; Sobrino y Sorio, 2009; Wan, 1999; Wan et al., 2002; Wang y Liang, 2009*).

En Argentina, la información de satélite ha sido ampliamente utilizada desde hace tiempo en el rango del espectro visible. Sin embargo, el avance en estudios que abarcan la región térmica del espectro es incipiente. En este sentido, el *Instituto de clima y agua (CIRN - CNIA - INTA Castelar)* desarrolla actividades de investigación centradas principalmente en el seguimiento de la vegetación natural y los cultivos a partir de información térmica de baja y alta resolución espacial. Para desarrollar esta actividad, posee antenas de recepción de imágenes de los satélites NOAA - AVHRR, GOES y MODIS.

Por otra parte, grupos de investigación como el grupo de *Teledetección y Evapotranspiración del Instituto de Hidrología de Llanuras (IHLLA)* ha enfocado sus esfuerzos en comprender y analizar los componentes del BE en diferentes cubiertas de la región pampeana (avena, soja, pasturas naturales), desarrollando modelos locales y regionales, combinando información de terreno con imágenes de satélite (*Carmona et al., 2010*).

Muchas aplicaciones en teledetección cuantitativa, como la estimación de BE y el monitoreo de ET requieren datos térmicos de resolución espacial  $\leq 500$  m (Kustas et al., 2003). Sin embargo, los sensores que poseen alta resolución espacial de datos térmicos están sólo disponibles a baja resolución temporal. En tal sentido, el uso conjunto de datos provenientes de satélites con diferentes resoluciones espaciales es necesario, convirtiendo los datos de sensores con baja resolución espacial a datos térmicos de moderada - alta resolución espacial con buena resolución temporal.

Existen técnicas de remuestreo basadas en diferentes aproximaciones metodológicas como el modelo lineal o espectral (Liu y Pu, 2008; Zurita-Milla et al., 2009), el de interpolación fractal (Kim y Barrows, 2002), el modelo físico analítico (Merlin et al., 2008), la disgregación secuencial (Merlin et al., 2009), y la de relación empírica (Kustas et al., 2003; Agam et al., 2007; Inandar and French, 2009; Chen et al., 2010; Jeganathan et al., 2011; Yang et al., 2011).

El remuestreo de datos de satélite es definido como el incremento de la resolución espacial disgregando los datos originales (Liang et al., 2004; Mukherjee, 2008; Jeganathan et al., 2011). En este trabajo, el término remuestreo (*Sharpening*) es usado para referirse a la disgregación de una imagen de resolución baja a una imagen de alta resolución usando una relación empírica entre las dos resoluciones.

En particular, una técnica basada en la relación empírica de la  $T_s$  y las condiciones de vegetación ha resultado tener una buena aproximación del remuestreo de datos térmicos. Estas aproximaciones están basadas en que la variabilidad en la  $T_s$  es manejada principalmente por la variación en la cobertura vegetal (Kustas et al., 2003; Agam et al., 2007 a, b). Esta relación cercana entre la  $T_s$  y cobertura vegetal se ha demostrado ampliamente en investigaciones previas (Sandholt et al., 2002; Mallick et al., 2009), denotando la existencia de una relación entre índice de vegetación -  $T_s$ , y su grado de vinculación dependerá de las condiciones climáticas y tipo de cobertura (Karnieli et al., 2006; Sun y Kufatos, 2007). Otras aproximaciones al remuestreo basado en la relación entre índices de vegetación y  $T_s$  fueron realizadas utilizando el porcentaje de vegetación (Agam et al., 2007 a, b), la emisividad (Inandar and French, 2009) e índices de estrés hídrico (Chen, et al., 2010).

Por otra parte, numerosos estudios se han presentado con la finalidad de obtener mapas y analizar la vegetación a diferentes escalas utilizando índices centrados en el comportamiento espectral de la vegetación. En tal sentido, el *Índice de Vegetación Normalizado* (*Normalized Difference Vegetation Index - NDVI*) propuesto por Rouse (1974) ha sido extensamente utilizado en estudios relacionados con vegetación, relacionándolo con el tejido vegetal (Myneni et al., 1995; Gitelson et al., 1996), la

concentración de clorofila en las hojas (*Broge y Leblanc, 2000*), la productividad primaria y la cobertura de vegetación (*Purevdorj et al., 1998; Gitelson et al., 1996*), el contenido de agua de las plantas (*Tucker, 1980*). También provee información del estado fenológico de las plantas (*Moulin et al., 1997*), encontrándose correlación con intercambio energético planta - atmósfera (*Sandholt et al., 2002; Mallick et al., 2009, Rivas et al., 2010*).

Es posible conocer el estado fenológico del cultivo en cada estadio de crecimiento de una planta, identificando condiciones de estrés hídrico a través de índices que dependen de la temperatura radiativa de la superficie (*Sandholt et al., 2002*). Además, los índices de estrés hídrico son utilizados para obtener de forma directa la estimación del contenido de agua presente en el sistema hidrológico (*Houspanassian et al, 2008; Rivas y Houspanossian, 2006*).

El objetivo principal de este trabajo fue proponer diferentes modelos de remuestros de datos térmicos basados en la relación empírica del NDVI -  $T_s$ , mejorar las aproximaciones actuales a través de índices de estrés hídrico y validarlos por medio de datos provenientes de estaciones de balance de energía. Además, estimar su utilidad para uso conjunto de diferentes sensores remotos en la región sub-húmeda de la Provincia de Buenos Aires.

Los objetivos específicos del trabajo fueron los siguientes:

- Estimar la temperatura de superficie utilizando imágenes Landsat 5 TM y MODIS Terra a partir del uso del software ENVI 4.7 (*ENvironmental Visualization of Image*).
- Proponer nuevas técnicas de disgregación de datos térmicos basados en el contexto NDVI -  $T_s$  y en el uso de índices de estrés hídrico como el Normalized Difference Infrared Index (NDII), Global Vegetation Moisture Index (GVMI), el Normalized Difference Water Index (NDWI) y el Soil Wetness Index (SWI).
- Realizar rutinas de programación relacionadas al remuestreo de datos térmicos desarrolladas en el entorno de programación de IDL (*Iterative Data Language*).
- Evaluar la precisión de los modelos de remuestreo desarrollados en este trabajo con respecto a la técnica DisTrad propuesta por *Kustas et al. (2003)*.
- Analizar la precisión de los modelos de remuestreo por medio de técnicas estadísticas de regresión, estimando la bondad de ajuste de los mismos a través de la determinación de coeficiente de correlación, considerando los estadísticos descriptivos e indicando los errores producidos por los modelos, mediante el uso del software estadístico R (*R Development Core Team, 2010*).

- Aplicar la técnica estadística geoespacial de semivariograma a fin de obtener muestras estadísticamente representativas.
- Validar los modelos de remuestreo con datos térmicos tomados *in situ* provenientes de estaciones de balance de energía.
- Estimar la utilidad de los modelos de remuestreo para obtener mayor disponibilidad temporal de imágenes de  $T_s$  a partir del uso conjunto de datos Landsat y MODIS.

Este estudio pretende aportar una mejora en los modelos de remuestreo de datos térmicos desarrollados hasta la actualidad, incorporando variaciones al modelo propuesto por *Kustas et al (2003)* mediante el uso de índices de estrés hídrico calculables a partir de datos de satélite y tomando en cuenta los límites seco y húmedo del espacio contextual NDVI -  $T_s$ . Se proponen cambios en la forma de establecer los límites que conforman el diagrama NDVI -  $T_s$  mediante la incorporación de la identificación del límite seco por ajuste cuadrático. Desde el punto de vista físico, el ajuste cuadrático representaría de mejor manera lo que sucede en el sistema planta, suelo y atmósfera.

El objetivo de las modificaciones en los modelos es incrementar la precisión de los mismos incorporando mayor variabilidad en la estimación de la  $T_s$  a partir de una mejora en la estimación del contenido de humedad del suelo. La mejora en la precisión se centra en lograr reproducir los cambios observados en el terreno, dominantes en el sistema agrícola pampeano, lo cual facilitará el seguimiento del sistema suelo agua planta de manera más precisa.

Además, aportar conocimiento de base para el uso conjunto de imágenes de satélite, específicamente para el sensor térmico NIRST a bordo del observatorio ambiental SAC - D. La información aportada por el sensor NIRST podría ser utilizada de forma conjunta con otras fuentes de información satelital que operen en el rango del espectro visible (por ejemplo MODIS).

Planteado el problema de investigación y los objetivos de la tesis, la tesis se organizó en cuatro partes principales subdivididas en 7 capítulos principales que son descriptas sucintamente a continuación.

La *parte I* se subdivide en 2 capítulos. En el capítulo 1 se plantea el problema de investigación, se presentan los objetivos generales y específicos, justificación y posibles aportes científicos. En el capítulo 2, se presenta la fundamentación teórica conjuntamente con los antecedentes existentes sobre la temática de remuestreos de datos térmicos.

En la *parte II* se presenta la metodología general utilizada en esta investigación conjuntamente con una breve caracterización del área de estudio. También se presentan las imágenes de satélite utilizadas y su procesamiento.

La *parte III*, referida a la presentación, descripción y discusión de los datos, se organizó en tres capítulos, cada uno de los cuales corresponde a la evaluación de los modelos propuestos para diferentes imágenes de satélite y su validación en campo.

En la *Parte IV*, se presentan las consideraciones finales, recomendaciones y perspectivas futuras. En Anexos, se incorpora la información complementaria que facilite al lector una mejor comprensión del trabajo presentado y se incluyen las rutinas de programación desarrolladas a partir del lenguaje IDL y R Statistic a fin de facilitar la reproducción de los resultados logrados.

## **Capítulo 2. FUNDAMENTACIÓN TEÓRICA**

### **2.1. ANTECEDENTES**

En las últimas décadas, se ha hecho necesario el uso de sensores remotos (SR) que provean imágenes de satélite de alta resolución espacial para monitorear la disponibilidad de agua en el suelo (DAS) y estimar de forma precisa las componentes del BE de la superficie terrestre.

Una correcta estimación de la  $T_s$  por medio de imágenes de satélite de alta resolución permitiría estudiar las variaciones de la disponibilidad de agua en el suelo y las condiciones de estrés hídrico de la vegetación a nivel de unidades de producción agrícola. Sin embargo, la disponibilidad de imágenes ópticas de alta resolución está condicionada por los largos períodos de revisita de los SR y por la nubosidad.

Las imágenes de baja resolución espacial y alta resolución temporal provistas por las plataformas satelitales EOS (MODIS), NOAA (AVHRR) y GOES se han utilizado para el monitoreo de variables hidrológicas a meso-escala por medio de técnicas de remuestreo que intentan reproducir la variabilidad de los datos térmicos contenidos en píxeles de menor resolución espacial (*Bierkens et al., 2000, Kustas et al., 2003*).

Durante los últimos años los modelos de remuestreo de datos térmicos se han aplicado y se han obtenido significativos avances, analizando el efecto de la resolución espacial sobre las características de la superficie. Sin embargo, la información sobre remuestreo hacia resoluciones menores es limitada, debido a que la mayoría de los remuestreos de datos han sido aplicados en sentido contrario (*Bian et al., 1999; Girolimetto et al., 2007; Hong et al., 2009*).

En este aspecto, *Kustas et al., (2003)* a través del uso de imágenes GOES y Landsat TM propone la estimación de la  $T_s$  y flujo de radiación térmica hacia la atmósfera a través de un modelo de remuestreo de datos térmicos llamado *Disaggregation Procedure For Radimetric Surface Temperature (DisTrad)*. Está basado en disgregar la imagen de  $T_s$  de menor resolución en una imagen de  $T_s$  de mayor resolución utilizando la relación empírica entre el NDVI -  $T_s$ , asumiendo que los valores de los píxeles de escala mayor son el promedio de los valores de la escala más fina (esta técnica se muestra con mayor detalle en el siguiente capítulo).

Por otra parte, la validación de los datos de satélite fue realizada por medio de imágenes de  $T_s$  de alta resolución estimada a través de datos aportados por el sensor aerotransportado TIMS (Thermal Infrared Multispectral Scanner) en la región de Texas - Nuevo México (Southern High Plains).

Este estudio concluye que no es posible distinguir variaciones en la  $T_s$  y flujo radiativo usando imágenes térmicas de baja resolución ( $10^3$  m), haciendo inviable la estimación de la tasa evaporativa de parcelas cultivadas.

*Li et al., (2004)* analizaron la variabilidad espacial de la  $T_s$  a diferentes resoluciones de píxeles comparando datos Landsat 5 TM, 7 ETM+, ASTER y MODIS Terra. Los resultados indicaron que cuando la resolución cambia de 60 a 960 m, el desvío estándar y el rango se reduce, debido a que los datos a una resolución baja pierden gran parte de la variabilidad espacial de la  $T_s$  contenida en el píxel. Además, integra datos térmicos y de humedad *in situ* para validar la  $T_s$  estimada, a través de campañas realizadas en dos regiones de Texas (Iowa y Ames) llamadas SMEX02 y SMACEX (*Soil Moisture Experiments* y *Soil Moisture - Atmosphere Coupling Experiment*).

Posteriormente, *Agam et al., (2007a, b)* redefinió el modelo DisTrad nombrándolo  $T_s$ HARP ( *$T_s$  Sharpening*). A diferencia del modelo propuesto por *Kustas et al. (2003)* basado en la relación NDVI- $T_s$ , éste se sustenta en la proporción o porcentaje de vegetación (*Fractional Vegetation Cover*). A partir de diferentes variaciones del modelo se obtuvieron resultados positivos sobre cultivos extensivos de maíz y soja a partir de imágenes Landsat 5 TM, 7 ETM+, MODIS Terra y GOES remuestreadas en la región central de Iowa. El mismo autor posteriormente simuló la  $T_s$  a partir de imágenes Landsat 7 ETM+ y MODIS Terra donde se aplicó el modelo  $T_s$ HARP sobre llanuras de Texas - Nuevo México, obteniendo errores por encima de 1,14 K.

*Hong et al. (2009)* establece la utilidad del remuestreo de los datos térmicos a partir del modelo SEBAL (*Energy Balance Algorithm for Land*) para estimar la evapotranspiración (ET) en cultivos, a partir de imágenes Landsat y MODIS en una porción de Valle Rio Grande en Nuevo México.

*Chen et al. (2010)* modifica el algoritmo  $T_s$ HARP llamándolo SWISF (*Soil Wetness Index Stepwise Fitting*), donde se incorpora un índice de humedad de suelo llamado SWI (*Soil Wetness Index*) utilizando imágenes ASTER. Además, incorpora el uso del límite seco y húmedo a través de funciones lineales extraídas del diagrama NDVI -  $T_s$  (ver en apartado 2.4 la definición de límites).

Recientemente, *Yang et al., (2011)* proponen una técnica de remuestreo basado en una red neuronal llamada DisEMIGA - SOFM para simular la  $T_s$  de la imagen de satélite ASTER a partir de

imágenes MODIS. Esta red neuronal incorpora un índice de estrés hídrico el NMDI (*Normalized Multi-band Drought Index*) y el SAVI (*Soil Adjusted Vegetation Index*), para ayudar en el entrenamiento de la red neuronal en la estimación de la  $T_s$ . Consecuentemente, la certeza del método DisEMI fue mayor que los resultados obtenidos por el modelo TsHARP, mostrando diferencias de 1 K.

*Jenganathan et al., (2011)* evalúa el modelo TsHARP sobre la base de diferentes aproximaciones (global, estratificada y local, entre otras), utilizando imágenes MODIS Terra y ASTER en el estado de Harayana (India). Este estudio muestra que el modelo basado en el análisis local (kernels) es considerablemente más preciso que el modelo global (imagen completa). Además, ha concluido que el error en la estimación de la  $T_s$  se incrementa en el mismo sentido de la resolución espacial de las imágenes.

La mayoría de las técnicas de remuestreo están basadas sobre modelos de ajuste lineal o cuadráticos considerando la totalidad de los píxeles en el contexto NDVI -  $T_s$ . (*Kustas et al., 2003; Kustas et al., 2004; Agam et al., 2007a-b; Li et al., 2008; Mukherjee, 2008; Inamdar y French, 2009; Merlin et al., 2009; Jeganathana et al, 2011; Yang et al., 2011; Yang et al., 2011*). Sin embargo, existen muy pocos antecedentes de modelos de remuestreo de datos con base metodológica en la utilización conjunta de los límites seco y húmedo. En un trabajo reciente publicado por *Chen et al., (2010)* se utilizó el límite seco y húmedo del diagrama NDVI -  $T_s$  para desarrollar un modelo de remuestreo basado en el Soil Water Index (SWI).

## 2.2. FUNDAMENTOS FÍSICOS

La importancia que la radiación electromagnética tiene para la teledetección radica en que la radiación constituye el medio por el cual se transmite la información. La radiación como forma de transmisión de energía se expresa en Julios ( $J$ ), por lo tanto, el flujo de energía puede expresarse por unidad de área, por unidad de tiempo ( $J/s = W$ ) o por unidad de tiempo y área ( $Wm^{-2}$ ).

La naturaleza de la radiación electromagnética puede ser explicada a partir del modelo de onda desarrollado por *Huygens y Maxwell* o por el modelo de partículas desarrollado *Planck y Einstein*. El primero asume que la radiación se produce como resultado de oscilaciones en los campos eléctricos y magnéticos en las inmediaciones de un objeto y se define según su longitud de onda ( $\lambda$ ) medida en  $\mu m$  ( $10^{-6}$  m) y frecuencia ( $\nu$ ) medida en hercios ( $s^{-1}$ ).

El modelo de partículas asume que la energía viaja como un flujo de partículas llamada fotón<sup>1</sup> ( $Q$ ) y la energía transportada por cada fotón depende del objeto que emite radiación. Ambos modelos se relacionan mediante la siguiente ecuación:

$$Q = \frac{hc}{\lambda} \quad (2.1)$$

Donde,  $h$  es la constante de *Planck* ( $6,626 \times 10^{-34}$  Js),  $c$  es velocidad de la luz ( $3 \times 10^8$  ms<sup>-1</sup>). Esta ecuación establece que la energía transportada es directamente proporcional a la frecuencia de la radiación e inversamente proporcional a la longitud de onda.

Todo cuerpo por encima de cero absoluto (273,15 K) emite radiación en forma de onda electromagnética que se transmite a la velocidad de la luz. Un cuerpo al aumentar la temperatura irradiará con mayor intensidad a una longitud de onda más corta (*Sobrino, 2000; Dingman, 2002, Chuvieco, 2008*). Por lo tanto, la cantidad de radiación emitida está en función de la longitud de onda y la temperatura del objeto.

La *ley de Planck* describe la distribución espectral de la radiación de un cuerpo negro<sup>2</sup> a una temperatura dada. La emisión radiativa de un cuerpo negro ( $L_\lambda$ ) es inversamente proporcional a su longitud de onda y representa la cantidad de energía emitida por cada longitud de onda por cada metro cuadrado de superficie del objeto cada segundo mediante la ecuación:

---

<sup>1</sup> Fotón es la onda electromagnética emitida por un electrón cuando baja de nivel energético.

<sup>2</sup> Un cuerpo negro es un radiador ideal que emite toda la radiación que recibe y su emisión es función de su temperatura.

$$L_{\lambda} = \frac{2\pi hc^2}{\lambda^5 \left[ \exp\left(\frac{hc}{\lambda kT}\right) - 1 \right]} \quad (2.2)$$

$L_{\lambda}$ , es la radiancia espectral de un cuerpo negro (CN) a una determinada longitud de onda  $\lambda$  medida en  $\text{Js}^{-1} \text{m}^{-2} \mu\text{m}^{-1}$ ,  $h$  es la constante de *Planck*,  $k$  la constante de *Boltzman* ( $1,38 \cdot 10^{-23} \text{W s}^2 \text{K}^{-1}$ ),  $c$  la velocidad de la luz y  $T$  la temperatura absoluta del cuerpo en Kelvin (K).

A partir de la expresión (2.2), se deriva la *ley de Stefan-Boltzman*, que permite calcular el total de la energía emitida por unidad de superficie y tiempo del cuerpo negro en función a su temperatura, sumando las emisiones para cada una de las longitudes de onda. Esta emisión máxima del CN puede calcularse por medio de:

$$M = \sigma T^4 \quad (2.3)$$

Donde,  $M$  es la emitancia radiativa ( $\text{W m}^{-2}$ ),  $T$  es la temperatura absoluta del cuerpo que emite (K),  $\sigma$  es la constante de *Stefan-Boltzman* ( $5,57 \cdot 10^{-8} \text{W m}^{-2} \text{K}^{-4}$ ). La energía total emitida no sólo varía con la temperatura, sino también con la distribución espectral de la energía emitida. La emitancia radiativa o radiancia espectral de un CN ( $\text{W m}^{-2} \mu\text{m}^{-1}$ ) viene dada por:

$$M_{\lambda} = \frac{C_1}{\lambda^3 \left( \exp\left(\frac{C_2}{\lambda T}\right) - 1 \right)} \quad (2.4)$$

Donde,  $C_1$  es  $3,74 \cdot 10^{-6} \text{W m}^{-2}$  y  $C_2$  es  $1,44 \cdot 10^{-2} \text{m K}$ .

La Figura 2.1 muestra las curvas de la distribución de energía para diferentes cuerpos negros, las unidades en el eje de las ordenadas expresan la emitancia radiativa de dichos cuerpos en  $\text{W m}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$  y en el eje de las abscisas se representan las longitudes de onda en micrones. La curva de emitancia radiativa del sol encuentra su máximo en el rango del espectro visible ( $0,4$  a  $0,7 \mu\text{m}$ ) con una temperatura promedio de  $6000 \text{K}$ , mientras que la superficie terrestre tiene su máximo en el rango espectral del infrarrojo térmico (de  $8$  a  $14 \mu\text{m}$ ) con una temperatura de aproximadamente de  $300 \text{K}$ , concentrando la máxima emisión de la superficie terrestre en la longitud de  $9,7 \mu\text{m}$  (*Dash et al., 2002*).

Cuando existe un incremento de la temperatura del radiador es más grande la cantidad total de radiación que emite, desplazando el máximo de la distribución de la radiación hacia longitudes de ondas más cortas. El área bajo la curva representa el total de energía ( $M$ ) por unidad de área y ángulo sólido.

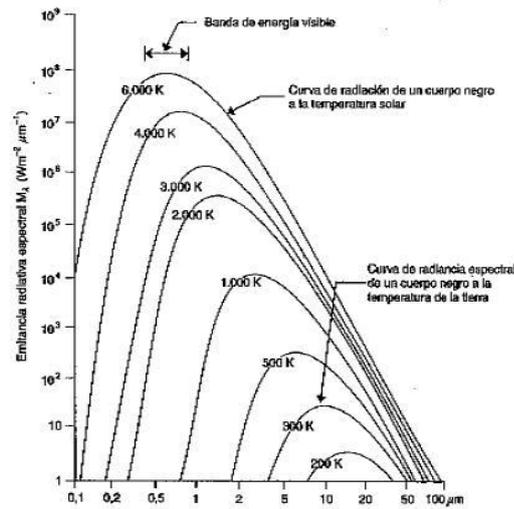


Figura 2.1: Curva de emittancia radiativa de un cuerpo negro a distintas temperaturas (Chuvieco, 2008).

La longitud de onda a la que se produce la máxima emisión de energía se conoce como longitud de onda predominante y se relaciona con la temperatura por medio de la *ley de desplazamiento de Wien*:

$$\lambda_{max} = \frac{2898}{T} \left( \frac{\mu m K}{K} \right) \quad (2.5)$$

Esta ley adquiere gran importancia para la teledetección cuantitativa, ya que permite seleccionar la banda espectral o longitudes de onda más convenientes para detectar un determinado fenómeno, siempre que se conozca su temperatura.

Hasta aquí hemos supuesto que las superficies naturales se comportan como cuerpos negros, lo que implica una notable simplificación. Las superficies naturales se comportan como cuerpos grises, lo que indica que tienen una emittancia espectral constante inferior a uno en todas las longitudes de onda. Entonces, como no todas las superficies naturales se comportan como cuerpo negro es necesario añadir el concepto de emittancia<sup>3</sup> ( $\epsilon$ ) según la *ley de Kirchoff*:

$$M = \epsilon M_{\lambda} \quad (2.6)$$

<sup>3</sup> La emittancia de un objeto es el factor que caracteriza la eficiencia de un objeto para radiar energía comparada con la energía radiada de un cuerpo negro a la misma temperatura.

Donde  $M$  es la irradiancia de la superficie natural en la longitud de onda ( $\lambda$ ),  $\varepsilon$  es la emisividad espectral del cuerpo a una determinada temperatura.

La *ley de Kirchoff* establece que para cada longitud de onda la absorbancia ( $\alpha$ ) de una superficie es igual a su emisividad [ $\alpha(\lambda) \approx \varepsilon(\lambda)$ ] (*Dash et al., 2002*). Los cuerpos naturales se los denomina radiadores selectivos debido a que suelen variar su emisividad con la longitud de onda. La emisividad puede tomar valores entre 0 y 1, por lo tanto, tiene valores de cero cuando la superficie refleja toda la energía que recibe y uno cuando absorbe y emite toda la energía, dependiendo de la superficie, la longitud de onda y el ángulo de observación.

### 2.3. TEMPERATURA DE SUPERFICIE

La  $T_s$  es un importante parámetro que controla la dinámica energética e hídrica entre la atmósfera y la superficie terrestre. La  $T_s$  se define como la energía térmica de onda larga que es emitida desde la superficie terrestre (*Valor y Caselles, 1996; Sobrino, 2000; Rivas y Caselles, 2004*).

La  $T_s$  puede ser estimada a partir de datos de satélite provenientes de SR que operan en el intervalo espectral térmico, si los efectos atmosféricos son removidos y la emisividad de la superficie es conocida, la temperatura de un reflector lambertiano puede ser determinada a través de la ecuación inversa a la *ley de Planck*:

$$T_\lambda = \frac{c_2}{\lambda \ln \left[ \frac{\varepsilon(\lambda)c_1}{\lambda^5 R} + 1 \right]} \quad (2.7)$$

Donde,  $T_\lambda$  es la temperatura de cuerpo natural a tope de la atmósfera (*TOA*) o temperatura de brillo en  $K$  y  $R$  es la radiancia espectral ( $W m^{-2} sr^{-1} \mu m^{-1}$ ),  $\lambda$  es la longitud de onda en  $\mu m$ ,  $\varepsilon(\lambda)$  es la emisividad espectral del cuerpo a una determinada longitud de onda,  $\pi$  es la constante matemática equivalente a 3,14159, la constante universal  $c_1$  es igual a  $1,19108 \cdot 10^8 W \mu m^4 m^{-2} sr^{-1}$  y  $c_2$  es igual a  $1,43877 \cdot 10^4 \mu m K$ . En la región del infrarrojo la temperatura de brillo también es equivalente a la temperatura de CN. La temperatura a TOA es generalmente menor que la temperatura de la superficie, variando en el rango de 1 a 5 K dependiendo de las condiciones atmosféricas (*Prata et al., 1995*).

El 80 % de la emisión térmica de la superficie terrestre se encuentra en el intervalo espectral comprendido entre 8 y 14  $\mu m$  (TIR). En esta región la atenuación de la señal por la absorción de aerosoles es despreciable, debido a que la concentración del vapor de agua, ozono ( $O_3$ ) y dióxido de

carbono (CO<sub>2</sub>) se encuentran en menor proporción (*Prata et al., 1993*). Esta región donde la transmisividad atmosférica es más elevada se denomina ventana atmosférica y es en esta ventana en la que se ubican las medidas que toman los diferentes sensores a bordo de las misiones de satélite.

Sin embargo, el vapor de agua afecta a la transmisión atmosférica de la radiación cinco veces más que el resto de los gases juntos, absorbiendo la radiación de onda larga del infrarrojo térmico y onda corta en microondas (desde los 22  $\mu m$  a 1mm). Por otra parte, el dióxido de carbono absorbe fuertemente la radiación en la región del infrarrojo lejano del espectro electromagnético, mientras que el ozono lo hace para las longitudes de ondas más chicas y energéticas (UVB).

En este sentido, la estimación de la T<sub>s</sub> está condicionada principalmente por el contenido de vapor de agua de la atmósfera, la emisividad de la superficie estudiada y ángulo de observación del SR (ángulos superiores a los 30°). Por lo tanto, una correcta estimación de la T<sub>s</sub> implica la consideración y corrección de estos factores.

La radiación emitida por una superficie a una longitud de onda dada, dentro del rango infrarrojo térmico, es función no sólo de su temperatura, sino que depende también de su emisividad. Se trata de un parámetro muy importante para los estudios del balance radiativo terrestre en onda larga. La ecuación de la emisividad está representada como la energía emitida por una superficie eficiente (*Valor y Caselles, 1996; Dash et al., 2002*) y viene dada por:

$$\varepsilon_i = \frac{R_i(T_s) - L_i^\alpha}{B_i(T_s) - L_i^\alpha} \quad (2.8)$$

Donde,  $\varepsilon_i$  es la emisividad de una superficie considerando la irradiancia atmosférica y la transmisividad de la atmósfera,  $R_i(T_s)$  es la radiancia espectral emitida por un cuerpo natural a una longitud de onda y temperatura dada medida en campo,  $B_i(T_s)$  es la radiancia emitida por un CN a una temperatura dada medida en campo, y  $L_i^\alpha$  es la irradiancia atmosférica.

Un cuerpo negro es un emisor perfecto, ya que tiene una emisividad de 1; sin embargo, las hojas de las plantas tienen valores de emisividad más atenuados en el intervalo 0,97 - 0,985, esto es debido a que parte de la energía incidente es reflejada, absorbida y transmitida en proporciones a diferentes longitudes de onda (*Rubio et al., 2003*).

Su valor es altamente dependiente de la composición de la superficie, sobre todo con su contenido de humedad, rugosidad y tamaño de sus partículas (*Barreto, et al., 2009*). También varía con la

longitud de onda en la cual es medida, resolución y ángulo de observación, dando una idea de la complejidad que representa su estimación.

Algunas de las técnicas para estimación de la emisividad de superficie son: Método de Emisividad Normalizada (NEM) propuesto por *Gillespie et al., (1985)*, el Índice Independiente de la Temperatura (TISI) propuesta por *Becker y Li, (1995)*; Separación de Emisividad (TES) propuesta por *Gillespie et al. (1998)*, y el método basado en índice de vegetación NDVI propuesto por *Valor y Caselles (1996)* y posteriormente modificada por *Rivas y Caselles (2004)*.

Globalmente, es conocida la necesidad de una correcta metodología que permita una rápida forma de estimar la  $T_s$ . Varios autores han trabajado en el desarrollo de algoritmos y metodologías para obtener la  $T_s$  a partir de datos de satélite (*Prata, 1993; Wan, 1999; Sobrino et al., 2002; Huete et al., 2002; Coll et al., 2005; Yang et al., 2006; Galve et al., 2008; Sobrino et al., 2009; Wang et al., 2009; Jimenez-Muñoz y Sobrino, 2003 - 2009; Yao et al., 2011*).

En los últimos años se han desarrollado tres tipos de algoritmos para estimar la temperatura radiativa de la superficie terrestre y oceánica a partir de la estimación de la temperatura de brillo a TOA, los cuales consideran la corrección de efectos atmosféricos, angulares y la emisividad de la superficie. Dentro de las diferentes metodologías existen los algoritmos *Monocanal*, *Split Window* y *Biangulares*.

Los algoritmos *monocanal* utilizan los valores de radiancia proveniente de un sólo canal centrado en la región térmica del espectro para corregir la temperatura de brillo a TOA. Puede ser aplicado a imágenes de satélites provistas por SR que tienen un canal térmico (por ejemplo Landsat 5 TM-ETM+ o Meteosat- MVIRI). La estimación de la  $T_s$  por el método monocanal requiere la precisa estimación del contenido de vapor de agua y emisividad de la superficie (*Jiménez Muñoz y Sobrino, 2003; Rivas y Caselles, 2004; Sobrino et al., 2002*). En este sentido, errores de  $\pm 0,005$  en la estimación de la emisividad afecta la precisión del algoritmo monocanal en  $\pm 2$  K (*Schädlich et al., 2001*). Por otro lado, la corrección atmosférica puede realizarse conociendo el contenido de vapor de agua mediante radiosondeos verticales (*Valor y Caselles, 1996; Rivas et al., 2010;*).

En cambio los algoritmos *Split Window* están basados en la absorción diferencial entre dos canales diferentes dentro de la misma ventana atmosférica a fin de eliminar la influencia de la atmósfera dentro del rango de 10,5 y 12,5  $\mu\text{m}$  (*Prata, A.J. , 1993; Coll y Caselles, 1997; Dash et al., 2002; Sobrino et al., 2002; Wang et al., 2009*). Entonces, calcula la  $T_s$  como una combinación lineal de dos temperaturas de brillo. Este método sostiene que la contribución en las temperaturas de los

dos canales son equivalentes y que la diferencia en la transmisividad de la atmósfera resulta en diferentes coeficientes de absorción en los dos canales debido principalmente el vapor de agua (a 11  $\mu\text{m}$  se encuentra la máxima transmisividad).

Por otra parte, el método biangular fue propuesto por *Chedin et al. (1982)* y puede ser aplicado mediante lecturas simultáneas de los SR en diferentes ángulos de observación. El método asume una uniformidad espacial de la columna atmosférica y debe haber una diferencia significativa en la trayectoria de observación, caso contrario el algoritmo pierde precisión (*Prata., 1993*). Además, las variaciones direccionales de la emisividad de la superficie deben ser estimadas a priori.

Los algoritmos biangulares utilizan la técnica de absorción diferencial en función a diferentes gradientes angulares de los SR cuando el objeto es observado con diferentes ángulos de visión en un mismo canal. La captura de datos puede ser realizada por un satélite o simultáneamente por satélites diferentes asumiendo que la variación angular de la emisividad es despreciable para ángulos mayores a 60° (*Prata, 1993, Sobrino et al., 1996*).

Finalmente, cabe decir que no existe un método para estimar la emisividad y  $T_s$  aplicable a diferentes regiones del planeta. Por lo tanto, se debe seleccionar la metodología de acuerdo a las características del área en estudio y las estimaciones de satélite deben ser validadas con datos de terreno tomados de estaciones *Ad Hoc*.

#### **2.4. CONTEXTO NDVI - $T_s$**

En los últimos años se ha utilizado el espacio generado entre la  $T_s$  y el NDVI para diferentes aplicaciones satelitales. Algunas de las aplicaciones involucran la estimación de variables hidrológicas como la estimación de la ET y el desarrollo de índices de EH para el monitoreo de sequías (*Wan et al., 2004; Bayarjargal et al., 2006; Rivas y Houspanossian , 2006; Houspanossian, et al., 2006*).

Este espacio es generado a partir de la relación empírica de la  $T_s$  y el NDVI. Como ya se expuso anteriormente, la temperatura radiativa de una superficie medida desde un SR es resultado de una compleja interacción que involucra factores físicos, fisiológicos y climáticos, donde la radiación recibida por el SR depende en gran parte del grado de cobertura de la vegetación, la evapotranspiración, el tipo de superficie (propiedades térmicas, rugosidad), las propiedades conductoras de la atmósfera, mecanismos fisiológicos de la planta y la humedad del suelo.

La otra variable teleobservada que define el espacio contextual es el NDVI. Este índice se sustenta en las propiedades reflectivas de la vegetación en la región del espectro visible (poco reflectiva) e infrarrojo cercano (altamente reflectiva). En la región del VIS (0,4 - 0,7  $\mu\text{m}$ ) la energía incidente es absorbida por los pigmentos vegetales (clorofila, carotenoides, etc) para el proceso de fotosíntesis y reflectividad de la hoja es pequeña (menos del 15 %). En cambio en el IRC (0,7 - 1,3  $\mu\text{m}$ ) la energía electromagnética es reflejada casi en su totalidad por las paredes celulares de la hoja.

El NDVI es definido como:

$$NDVI = \frac{\rho(0,86\mu\text{m}) - \rho(0,66\mu\text{m})}{\rho(0,86\mu\text{m}) + \rho(0,66\mu\text{m})} \quad (2.9)$$

El NDVI cercano a uno indica alta cobertura de la vegetación y NDVI cercano a cero indica suelo desnudo. Valores intermedios corresponden a píxeles mixtos compuestos por una proporción de vegetación y otra de suelo desnudo.

Numerosos estudios han sugerido que la información combinada de la  $T_s$  y el NDVI puede proporcionar una mejor información sobre el estrés hídrico de la vegetación y las condiciones de humedad en el suelo (*Sandholt et al., 2002; Carlson, 2007*). La interpretación física del espacio triangular generado por la relación NDVI- $T_s$  se ha explorado con rigor en diferentes estudios con el propósito de conocer el estado hídrico de los cultivos (*Moran et al., 1994; Carlson et al., 1995; Gillies y Carlson, 1995; Goetz, 1997; Sandholt et al., 2002; Kustas et al., 2003; Anderson et al., 2004; Hope et al., 2005; Wang et al., 2006; Rivas et al., 2007; Stisen et al., 2008; Mallick, et al., 2009*).

Para interpretar el diagrama contextual NDVI -  $T_s$  es necesario conocer los mecanismos y factores que determinan la ubicación de un píxel en este espacio. Toda la energía utilizada en los procesos físicos y biológicos de la tierra proviene del sol, por ende, es importante cuantificar la cantidad de radiación solar recibida (onda corta) y emitida (onda larga) en la superficie de la tierra. El BE engloba la suma de todas las contribuciones de la radiación de onda corta y onda larga que entran y salen de la superficie, representando convenientemente la forma en la cual se distribuye la radiación neta en un sistema formado por vegetación, suelo y atmósfera (*Monteih y Unsworth, 1990; Ibañez Plana, 1998; Sánchez et al., 2008; Rivas y Carmona, 2010*). El BE simplificado se expresa como:

$$Rn = LE + H + G \quad (2.10)$$

Donde,  $Rn$  es la radiación neta,  $LE$  es el flujo de energía asociado al proceso de evapotranspiración (la  $LE$  es equivalente a la  $ET$ ) y es resultado del producto entre el calor latente de evaporación ( $L$ ) y la tasa de evaporación ( $E$ ),  $H$  es el flujo de calor sensible y  $G$  es el flujo de calor en el suelo (expresado en unidades de energía).

El mecanismo que regula la  $T_s$  a través del BE es la evapotranspiración<sup>4</sup>( $ET$ ). En este aspecto, cuanto menor sea el flujo de energía asociado a la  $ET$ , más energía disponible para liberar hacia la superficie ( $H$ ) (Sandholt et al., 2002; Hope et al., 2005). Por lo tanto, la resistencia estomática a la transpiración es un factor clave, controlado en parte por la disponibilidad de agua en el suelo.

La capacidad de transferir calor desde la superficie terrestre hacia la atmósfera es un componente importante en el control de la  $T_s$ . En superficies vegetadas con alta rugosidad se observan menores valores de  $T_s$  en comparación con el suelo desnudo y seco. Sin embargo, en superficies vegetadas homogéneas, con suministro de agua ilimitado (por ejemplo regadíos) pueden darse mayores valores de  $T_s$  de lo esperado, si el intercambio turbulento se reduce por la pobre mezcla (Nemani y Running, 1997).

En superficies parcialmente vegetadas, la  $T_s$  es influenciada por la inercia térmica<sup>5</sup> del suelo, ya que produce un calentamiento diferencial entre las superficies vegetadas y no vegetadas haciendo variar la cantidad de calor transferido ( $G$ ). Estas propiedades térmicas varían fuertemente con el tipo de suelo, y con los cambios en la humedad de éste.

Por otra parte, la energía incidente disponible en la superficie ( $Rn - G$ ) también afecta a la  $T_s$ . El control radiativo de la  $T_s$  implica que en áreas con poca radiación solar entrante (onda corta) o alto albedo, tendrá menor temperatura radiativa la superficie (Mallick et al., 2009). El albedo es controlado por el tipo de suelo, humedad de suelo y cobertura vegetal.

La radiación incidente también afecta la resistencia estomática a la transpiración, regulando la apertura y cierre de los estomas, debido a alteraciones en la partición de la radiación neta en calor sensible ( $H$ ) y latente ( $LE$ ).

El triángulo de la Fig. 2 representa la distribución en el espacio bidimensional de cobertura total (A), cobertura parcial (B), suelo desnudo (C). En este espacio contextual, se observa que la  $T_s$  (eje

---

<sup>4</sup> La evapotranspiración ( $ET$ ) puede definirse como el proceso de transformación de la fase líquida del agua de una superficie libre a la fase de vapor, sumando la componente evaporación ( $E$ ) y transpiración de las plantas ( $T$ ).

<sup>5</sup> propiedad que indica la cantidad de calor que puede conservar un cuerpo y la velocidad con que lo cede (ver Sobrino, 2000)

Y) es diagramada en función del NDVI (eje X). La hipotenusa del triángulo representa el límite seco (línea roja llena), el cual agrupa mayores valores de  $T_s$ , indicando que no existe humedad para las diferentes clases de NDVI. Por lo tanto, a medida que la vegetación vigorosa aumenta a lo largo del eje X, la  $T_s$  máxima ( $T_{max}$ ) disminuye.

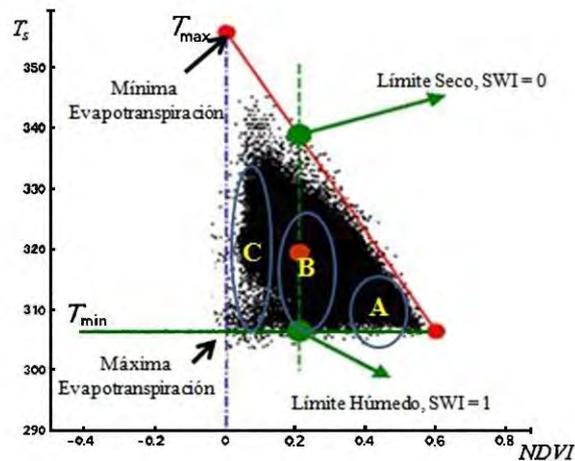


Figura 2.2: Espacio NDVI- $T_s$  modificado de Girolimetto et al. (2007).

El límite seco teórico representa humedad cero y evapotranspiración cero, y la  $T_s$  alcanza el máximo físico cuando no se produce el enfriamiento por evaporación. En este contexto, ocurre el cierre estomático completo de la vegetación (Moran, 1994). Sin embargo, la evapotranspiración cero raramente ocurre para vegetación densa, incluso para ambientes semiáridos, debido principalmente a que existe un aporte hídrico a través del agua higroscópica retenida cerca de las raíces de las plantas. En consecuencia, el límite seco observado a partir de imágenes de satélite es caracterizado por temperaturas más bajas que el límite seco teórico.

En contraste, el límite húmedo y frío (línea verde llena) identificado por los valores de  $T_s$  más bajos (base del triángulo), tiene la mayor cantidad de humedad del sistema para todas las clases de NDVI, representando la máxima evapotranspiración. Considera los puntos formados por la línea horizontal o con pendiente al nivel de  $T_{min}$  para diferentes tipos de coberturas.

El borde izquierdo (línea azul punteada) representa a suelos desnudos que van de seco a húmedo (de arriba hacia abajo). Para suelos desnudos la  $T_s$  está determinada principalmente por el contenido de humedad, siendo factores como la evaporación y las propiedades térmicas de la superficie quienes regulan el proceso.

En imágenes de satélite la aproximación teórica del espacio contextual NDVI -  $T_s$  se observa solamente cuando se considera la totalidad de la escena en la zona de estudio que contenga los extremos. Por otra parte, la correlación entre la  $T_s$  y la vegetación depende principalmente de la estación del año y la hora del día (*Carlson, 2007*). El efecto de enfriamiento de la vegetación es mucho mas fuerte durante las horas diurnas que sobre las horas nocturnas. Además, una fuerte correlación negativa entre el NDVI -  $T_s$  se produce entre el equinoccio de primavera y el solsticio de verano, mientras que para el solsticio de invierno la correlación entre las variables tiene pendiente positiva (*Sun y Kufatos, 2007*).

## **2.5. REMUESTREO DE DATOS TÉRMICOS**

El modelo de remuestreo de datos de temperatura de superficie a nivel de subpíxel llamado DisTrad fue desarrollado por *Kustas et al., (2003)* y posteriormente modificado por *Anderson et al., (2004)* quien lo denominó  $T_s$ HARP. Esta metodología está basada en el espacio NDVI -  $T_s$ , asumiendo que existe una única relación inversa entre las variables a diferentes resoluciones espaciales (*Fig. 2.3*).

Esta relación puede ser definida por medio de la variación de la pendiente, estrechamente relacionada con cambios en la cobertura vegetal, la estación del año, la escena y el sitio estudiado (*Karnieli et al., 2006; Raynolds et al., 2008; Jeganathan, et al., 2011*).

Con base en la correlación negativa entre el NDVI -  $T_s$ , el modelo de remuestreo  $T_s$ HARP refleja la relación local entre la temperatura de superficie y la proporción de vegetación por medio de una regresión lineal o de cuadrados mínimos entre las variables, donde el NDVI es la variable independiente y la  $T_s$  es la variable dependiente. Los parámetros de la función de remuestreo deben ser determinados dentro del contexto NDVI -  $T_s$  para el total de los píxeles de la escena que será remuestreada (*Agam y Kustas, 2007*).

El primer paso metodológico de  $T_s$ HARP es definir una regresión en el espacio NDVI -  $T_s$  de la imagen de satélite donde ambas variables se encuentran a una resolución baja o también llamada grosera. Los parámetros de la regresión son utilizados para simular o estimar la  $T_s$  en función del NDVI por medio de la siguiente expresión:

$$T_s^*(NDVI_{Baja}) = f(NDVI_{Baja}) \quad (2.11)$$

Posteriormente los parámetros de la regresión se aplican a la imagen de alta resolución de NDVI. El símbolo asterisco indica el valor de temperatura simulada usando el índice de vegetación NDVI. La ecuación (2.11) refleja solamente condiciones promedios despreciando la proporción de agua contenida en plantas y suelo. La variabilidad producida por el efecto de la humedad del suelo es incorporada por medio de la siguiente ecuación:

$$\Delta t = T_{s\text{Baja}} - T_{s\text{Baja}}^* \quad (2.12)$$

Donde,  $\Delta t$  es la diferencia o residual resultante de la diferencia entre la temperatura observada ( $T_{s\text{Baja}}$ ) y la temperatura estimada  $\Delta T_{s\text{baja}}^*$ .

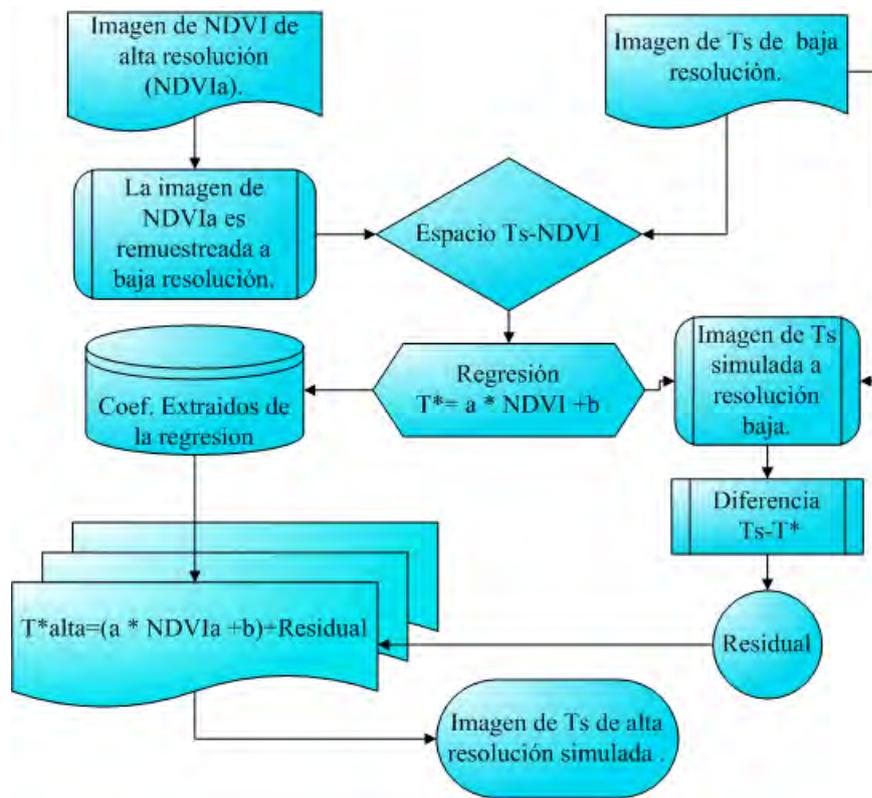


Figura 2.3: Esquema general del método de remuestreo de datos térmicos propuesto por Kustas (2003).

Como se observa en la Figura 2.3, la temperatura de superficie a nivel de subpíxel ( $T_{s\text{Alta}}^*$ ) es estimada a partir de la siguiente expresión:

$$T_{s\text{Alta}}^* = T_{s\text{Baja}}^*(NDVI_{\text{Alta}}) + \Delta t \quad (2.13)$$

Donde,  $(T_s^*_{Alta})$  es la  $T_s$  de alta resolución,  $(\Delta t)$  es el residual de la temperatura y  $T_s^*(NDVI_{Alta})$  es la imagen de  $T_s$  resultante de ampliar los parámetros de la regresión al NDVI de alta resolución ( $NDVI_{Alta}$ ).

El modelo  $T_s$ HARP presenta una serie de limitaciones inherentes a la relación NDVI- $T_s$  como:

a). Los parámetros de la regresión están fuertemente condicionados por el factor estacionario, en términos relativos la pendiente de la regresión cambia dependiendo de la estación del año estudiada (Foody, 2004; Kufer y Farris, 2007, Sun y Kufatos, 2007).

b). El residual de temperatura (ecuación 2.12) calculado sobre los datos a baja resolución espacial, producen un ajuste en los valores de los píxeles, corrigiendo la variabilidad espacial de los datos de  $T_s$ . Sin embargo, es de esperar que a altas resoluciones esta compensación no llegue a representar adecuadamente la variabilidad de los datos.

c). El modelo de remuestreo utiliza los coeficientes de regresión calculada en la baja resolución espacial y posteriormente los aplica a la imagen de NDVI de alta resolución. Esto supone que la relación de regresión es la misma en dos resoluciones espaciales. Sin embargo, no está claro hasta qué punto los valores reales de los coeficientes de regresión son invariante en escala.

Como hemos visto, la mayoría de los problemas están relacionados con el NDVI. Una de las razones podría estar vinculada a la incapacidad que tiene el NDVI para representar correctamente los efectos de la humedad de superficie. Este inconveniente puede ser solucionado mejorando la estimación de la humedad de superficie a través de índices de estrés hídrico, representando de mejor manera la variabilidad térmica contenida en la escena.

## 2.6. ÍNDICES DE ESTRÉS HÍDRICO

En este apartado se realiza una breve síntesis de los índices de estrés hídrico utilizados en el trabajo. Se explicará de forma sucinta la justificación teórica en relación al uso de índices de estrés hídrico centrados en la región del espectro visible e infrarrojo cercano para la estimación de la humedad del suelo y sus posibles aplicaciones en el remuestreo de datos térmicos.

Variaciones de la humedad de suelo producen cambios significativos en el BE de la superficie y en la productividad de la vegetación, y estos se encuentran directamente relacionado con la estimación del estrés hídrico<sup>6</sup>. La disponibilidad de agua del sistema hidrológico puede ser estimada a nivel regional por medio del uso de sensores remotos combinando información con datos proporcionados por estaciones meteorológicas. En este sentido, para obtener la variación espacial de la disponibilidad de agua en la superficie es necesario aplicar indicadores de las condiciones hídricas de la superficie a partir de una combinación de bandas en diferentes longitudes de onda electromagnética.

En las últimas décadas muchas investigaciones proponen relaciones entre el contenido de agua de la vegetación e índices espectrales que utilizan diferentes regiones del espectro (VIS, IRC y IRM) para estimar el contenido relativo de agua en las hojas en término del espesor equivalente de agua expresado en  $\text{g cm}^{-2}$  (Ceccato et al, 2001 - 2002; Fensholt & Sandholt, 2003; Basso et al., 2004; Danson & Bowyer, 2004; Camacho et al., 2009). En tal sentido, un amplio número de relaciones entre bandas espectrales han sido propuestos para el censado remoto del agua en las plantas, utilizando la región plana de alta reflectividad en el sector del infrarrojo cercano (IRC), el cual permanece invariante sin importar el estado hídrico de las plantas y bandas centradas en el infrarrojo medio (IRM) sensibles a la absorción de la radiación por el contenido de agua presente en la vegetación. Algunos de los índices que utilizan estas regiones de espectro son: el Normalized Difference Infrared Index (Fensholt & Sandholt, 2003), el Normalized Difference Water Index (Gao, 1996), los Short Wave Infrared Water Stress Index (SIWSI 6,2/5,2) (Fensholt & Sandholt, 2003), el Global Vegetation Moisture Index (Ceccato y Gobron, 2002) y el Normalized Multi-band Drought Index (Wan y Qu, 2007).

---

<sup>6</sup> se considera que una planta sufre estrés o déficit hídrico cuando el potencial del agua en sus tejidos decrece tanto como para afectar negativamente al funcionamiento de los procesos fisiológicos.

Recientemente se han desarrollado índices de estrés hídrico combinando índices de vegetación y  $T_s$ , extrayendo los parámetros necesarios para su estimación del espacio NDVI -  $T_s$ . (Sandholt et al., 2002; Rivas y Houspanossian, 2006). En este sentido, los índices como el Temperature Vegetation Dryness Index (Sandholt et al., 2003) y Soil Wetness Index (Mallick et al., 2009) utilizan el espacio NDVI -  $T_s$  para la estimación de la humedad relativa de la superficie terrestre.

En este trabajo se utilizaron los índices Normalized Difference Infrared Index (NDII) propuesto por Hardisky et al (1983), el Global Vegetation Moisture Index (GVMI) propuesto por Ceccato et al (2002), el Normalized Difference Water Index (NDWI) propuesto por Gao (1996) y el Soil Wetness Index (SWI) propuesto por Mallick et al. (2009). Éstos utilizan información de distintas bandas pertenecientes el IRC y IRM para estimar el contenido de agua del dosel de las plantas ( $\text{g H}_2\text{O m}^{-2}$ ) y se encuentran centrados en intervalos espectrales donde la transmisividad de la atmósfera es cercana al 100 % (Fensholt & Sandholt, 2003).

El Normalized Difference Infrared Index (NDII) y el Global Vegetation Moisture Index (GVMI) utilizan el intervalo espectral de  $0,86 \mu\text{m}$  (IRC) y  $1,6 \mu\text{m}$  (IRM) normalizando la diferencia entre ambas son definidos como:

$$NDII = \frac{\rho(0,86 \mu\text{m}) - \rho(1,64 \mu\text{m})}{\rho(0,86 \mu\text{m}) + \rho(1,64 \mu\text{m})} \quad (2.14)$$

$$GVMI = \frac{(\rho(0,86 \mu\text{m}) + 0,1) - (\rho(1,64 \mu\text{m}) + 0,02)}{(\rho(0,86 \mu\text{m}) + 0,1) + (\rho(1,64 \mu\text{m}) + 0,02)} \quad (2.15)$$

El Normalized Difference Water Index (NDWI) también utiliza una diferencia normalizada pero para comparar las reflectividades del sector del espectro de  $0,86 \mu\text{m}$  (IRC) y  $1,24 \mu\text{m}$  (IRM).

$$NDWI = \frac{\rho(0,86 \mu\text{m}) - \rho(1,24 \mu\text{m})}{\rho(0,86 \mu\text{m}) + \rho(1,24 \mu\text{m})} \quad (2.16)$$

La firma espectral de la vegetación seca incrementa el porcentaje de energía reflejada en el mismo sentido que la longitud de onda en el intervalo  $0,8-1,3 \mu\text{m}$ , cerca de  $1,2 \mu\text{m}$  se presenta un pico de absorción atribuido a la presencia de celulosa (Fig. 2.4 a, b). Los índices de EH son sensibles a cambios en el contenido de agua líquida de la vegetación y pueden ser observados en el intervalo espectral de  $0,86$  a  $1,64 \mu\text{m}$ . En este sentido, se puede observar que para el intervalo de  $0,86 \mu\text{m}$  la absorción es despreciable y la reflectividad se mantiene constante, mientras que en el rango  $1,24$  y  $1,64 \mu\text{m}$  se generan picos de absorción cuando existe disponibilidad de agua (DA) en el sistema

suelo-planta-atmósfera (Fig. 2.4 a). En cambio, cuando la vegetación está en estado senescente la disponibilidad de agua decrece produciendo altas reflectividades (Fig. 2.4 b).

La pendiente positiva y negativa de la recta muestra un comportamiento característico para cada índice, dependiendo de la DA en la vegetación. Particularmente, el NDII conserva la pendiente negativa independientemente de contenido de agua líquida en la vegetación. Por otra parte, el NDWI utiliza el canal espectral 1,24  $\mu\text{m}$  para evitar el efecto de la celulosa en la estimación. A pesar de estas diferencias el significado de los índices es equivalente, donde los valores negativos entre -1 y 0 indican estrés hídrico y los valores positivos entre el intervalo 0 - 1 representan buenas condiciones hídricas.

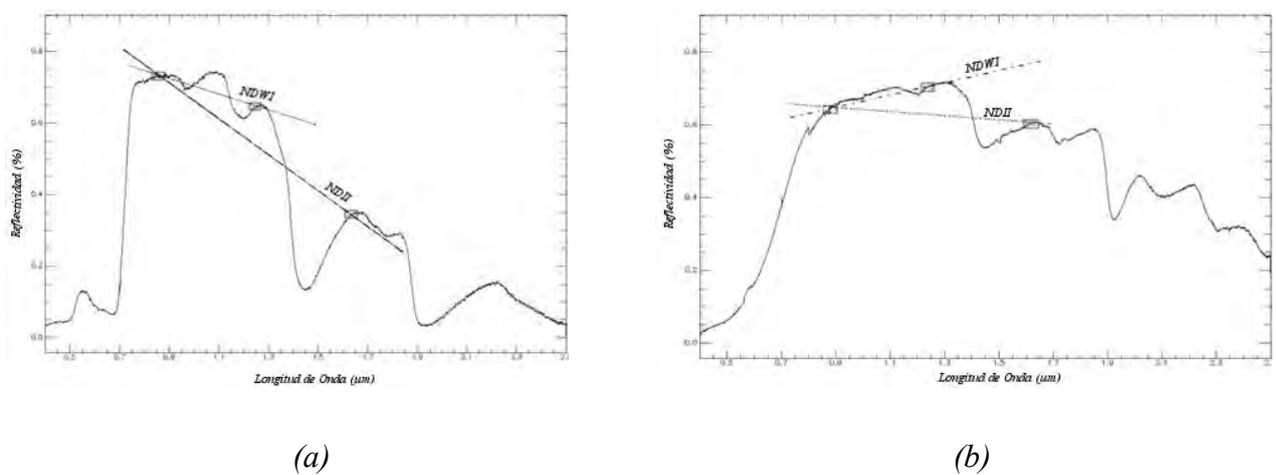


Figura 2.4: a) Respuesta del NDII y NDWI en vegetación con estado hídrico óptimo, b) Respuesta espectral de la vegetación senescente bajo estrés hídrico (Extraído de Ormeño, 2006).

El índice SWI planteado sobre el espacio NDVI -  $T_s$  fue propuesto por Mallick et al (2009), utiliza la  $T_{s \text{ max}}$  identificable en toda la extensión del límite seco. Asume que la disponibilidad de agua varía linealmente desde el límite seco al húmedo, representando las condiciones de máximo estrés hídrico con valores cercanos a 0 y las condiciones de máxima humedad representadas por la  $T_{s \text{ min}}$  través del límite húmedo con valores cercano a 1 (Carlson, 2007; Stisen et al, 2008). El SWI se define como:

$$SWI = \frac{T_{s \text{ max}} - T_s}{T_{s \text{ max}} - T_{s \text{ min}}} \quad (2.17)$$

Donde,  $T_s$  es la temperatura de superficie para el píxel considerado,  $T_{s \text{ max}}$  es la temperatura máxima definida en el espacio NDVI -  $T_s$  y la  $T_{s \text{ min}}$  es la temperatura mínima definida en el mismo espacio.

***PARTE II***

***MATERIALES Y MÉTODO***

### Capítulo 3. CARACTERIZACIÓN DEL ÁREA DE ESTUDIO y DATOS UTILIZADOS

La zona de estudio está ubicada en la llanura pampeana la cual presenta clima sub húmedo-húmedo con déficit de agua poco significativo. La región presenta clima templado con temperatura media del aire ( $T_a$ ) de 14 °C, encontrándose una media máxima de 21,5 °C en enero y una media mínima de 7,2 °C en julio, una humedad relativa (HR) media del aire de 70,5 %, una velocidad media del viento ( $u$ ) de 2,6 m s<sup>-1</sup> y una radiación solar media de 186 W m<sup>-2</sup> (Carmona et al., 2010b)

Según el balance hídrico *Thonthwaite* (1957) para el período 2000 - 2008, realizado por *Weinzettel, P. y Usunoff, E.* (2001 a,b) indicó una precipitación media anual de 900 mm, una evapotranspiración real 765 mm respectivamente, un déficit poco significativo de 18 mm en total en los meses de verano, y excesos hídricos de 144 mm distribuidos principalmente en los meses de invierno. Se muestra un claro predominio del exceso hídrico en gran parte del año exceptuando el periodo estival, representando la evapotranspiración real el 85 % del total precipitado. Por otro lado, la región pampeana posee bajos gradientes hidráulicos, favoreciendo el proceso de infiltración de agua en contraposición del proceso de escorrentia superficial.

En este trabajo se utilizaron imágenes de satélite provenientes de diferentes sensores correspondientes al área de estudio. Se utilizó un total de 4 imágenes captadas por el sensor MODIS Terra a bordo de la plataforma EOS Terra e imágenes del sensor TM de la misión Landsat 5 (escena 225/86 del *World-wide Reference System*) (Tabla 3.1).

<i>Imágenes</i>	<i>Sensor</i>	<i>Fecha de adquisición</i>
(1)	MODIS	10/11/2006
(2)	TM	11/11/2006
(3)	MODIS	23/02/2010
(4)	TM	23/02/2010

Tabla 3.1: Imágenes MODIS y Landsat utilizadas en el trabajo.

En la Tabla 3.1 se presentan las fechas de adquisición de las imágenes MODIS Terra y Landsat TM utilizadas en el trabajo. Las imágenes fueron elegidas en función a la disponibilidad de datos de terreno para la validación de los modelos de remuestreo y las condiciones de terreno en el área de referencia eran óptimas (baja nubosidad, atmósfera con bajo contenido de vapor, cobertura vegetal máxima y humedad de suelo elevada).

Las imágenes MODIS Terra fueron cedidas por la Comisión Nacional de Actividades Espaciales de Argentina (CONAE) con nivel de procesamiento 1B y la imagen Landsat 5 fue bajada del sitio web del Instituto Nacional de Investigaciones Espaciales de Brasil (INPE) (<http://www.dgi.inpe.br/catalogo/>) con nivel de procesamiento 5L. Del total de la escena Landsat se consideró un área de 13.551 km<sup>2</sup> para el desarrollo del trabajo y para la escena MODIS se consideró un área de aproximadamente 586.000 km<sup>2</sup> comprendiendo casi la totalidad de la provincia de Buenos Aires.

Previo a la estimación de la temperatura de superficie se realizaron un conjunto de correcciones sobre los datos a ser utilizados en los modelos de remuestreo. Los apartados siguientes describen las técnicas de procesamiento de imágenes que se aplicaron en la calibración, en la corrección geométrica, en la corrección atmosférica; y además, se presentan los algoritmos monocanal y split window que se utilizaron para la estimación de  $T_s$  de las imágenes Landsat 5 TM y Terra MODIS. El procesamiento de las imágenes fue realizado por medio del software ENVI 4.7 (*ITT- Reserch System Inc., Boulder, CO, USA*). El sistema de proyección utilizado para geolocalizar las imágenes Landsat 5 TM y MODIS fue UTM, Datum WGS-84, zona 21 Sur.

Para la validación de los modelos se utilizaron datos locales registrados para el día 10/11/2006 (día juliano 314) y el 23/02/2010 (día juliano 54). Para el día juliano 54 se utilizaron datos puntuales provenientes de la EBE instalada en una parcela con cultivo de soja de 5 ha en el establecimiento agrícola Laura Leofú (37° 14' S, 59° 34' O). Este establecimiento se encuentra ubicado en la zona centro de la provincia de Buenos Aires, en cercanías de la ciudad de Tandil, donde se practica agricultura intensiva de precisión por ambientes (*Fig. 3.1*). La EBE fue configurada para almacenar los valores promedios por los sensores cada 15 minutos en un datalogger CR 10X (Campbell Scientific, inc) alimentado por una batería de 12 V conectada a un panel solar de 20 W. Cuenta con dos sensores de  $R_n$  ubicados a 2,15 m sobre la superficie. El primero es un radiómetro CRN1 Net (Kipp & Zonen) que mide la radiación de onda corta de forma separada, utilizando el piranómetro CM3up ( $Rs_{\uparrow}$ ) y el CM3down ( $Rs_{\downarrow}$ ) en intervalo espectral 0,305 a 2,80  $\mu\text{m}$ . La radiación de onda larga se mide por medio de un radiómetro CG3up ( $Rl_{\downarrow}$ ) y CG3down ( $Rl_{\uparrow}$ ) con rango espectral 5 – 50  $\mu\text{m}$ . El segundo radiómetro neto es un NR-LITE (Campbell Scientific, inc.) que opera en el intervalo 0,2 – 100  $\mu\text{m}$  (*Carmona et al., 2011*).

La estación de BE<sup>7</sup> contiene sensores de *temperatura y humedad relativa del aire CS215-L16 (Campbell Scientific, Inc.)* a la misma altura que el radiómetro neto y un sensor de dirección/velocidad horizontal de viento MOII 034B (*Campbell Scientific, Inc.*) en la parte más alta de la estación.

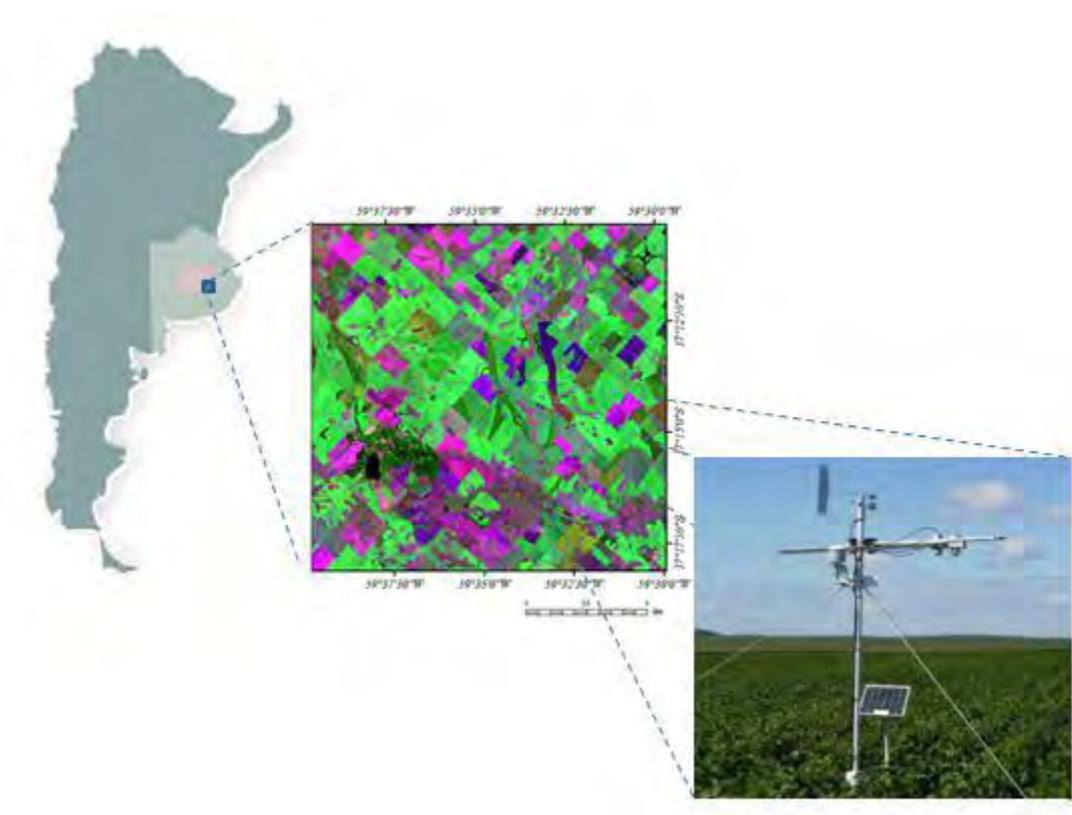


Figura 3.1: Ubicación relativa de la EBE instalada en la parcela de soja en el establecimiento agrícola Laura Laufú (37° 14' S, 59° 34' O) y estación con sensores. La imagen central muestra un recorte de la imagen captada por el sensor TM del día 23/02/2010 (RGB 247).

La temperatura radiativa ( $T_{\text{rad}}$ ) fue estimada a partir de un sensor de alta precisión IRR-1505 (Apogee Instruments, Inc.), instalado a la misma altura que los sensores de  $R_n$ . Este sensor mide la temperatura mediante la detección de la radiación infrarroja recibida en el intervalo 8 a 14  $\mu\text{m}$ , con un IFOV de 22°. La  $T_{\text{rad}}$  se registra en un intervalo de -15° a 60° C con una precisión de  $\pm 0,2$  °C.

Por otra parte, para la validación de los datos estimados el día juliano 314 se utilizaron datos de terreno a partir de 38 observaciones *in situ* utilizando un radiómetro IRT portátil marca Raytex

---

<sup>7</sup> para conocer los detalles técnicos del instrumental de la EBE consultar Carmona *et al.*, 2010.

modelo ST Pro (Fig. 3.2). La transecta fue realizada en la unidad productiva llamada “Tata Dios”, ubicada en la ruta provincial N° 30 con dirección a la ciudad de Rauch al NE de la ciudad de Tandil, con coordenadas geográficas 37° 06’45” S y 58°58’50” O.



*Figura 3.2: Fuente de calibrado y sensor Raytex en etapa de intercalibrado.*

El radiómetro Raytex mide la radiación electromagnética en el intervalo espectral de 8 a 14  $\mu\text{m}$  registrando la  $T_s$  desde 0 a 50 °C (273,15 a 323,15 K) con un error estimado de  $\pm 0,82$  K. Se utilizó un cuerpo negro marca Everest como fuente de calibrado del radiómetro portátil, con error estimado de  $\pm 0,1$  K e intervalo de 0 a 60 °C.

## Capítulo 4. METODOLOGÍA

### 4.1. MODELOS DE REMUESTREO DE DATOS TÉRMICOS

Sobre la base teórica del método TsHARP descrito en el capítulo 2, se elaboraron y utilizaron diferentes aproximaciones metodológicas de remuestreo que permitan mejorar la estimación de la temperatura a nivel de subpíxel. A continuación se exponen las técnicas propuestas en esta investigación.

#### 4.1.1. MODELO FCLS (Función Cuadrática del Límite Seco).

El modelo FCLS es propuesto en este trabajo como alternativa de la técnica TsHARP explicada anteriormente. Está basado en la relación empírica entre el NDVI -  $T_s$  y propone utilizar el límite seco generado en ese contexto a través de un ajuste cuadrático (Fig. 4.1).

Mukherjee (2008) estableció la comparación entre el modelo de regresión lineal y el cuadrático en el espacio NDVI -  $T_s$  con el propósito de identificar el modelo que presenta la mejor significancia por medio de un test de ANOVA, con un intervalo de confianza de un 95 %. El modelo que resultó más significativo fue el modelo cuadrático. En este estudio se analizaron los valores correspondientes al límite seco del espacio NDVI -  $T_s$  donde se obtuvieron resultados similares por medio del coeficiente  $R^2$ .

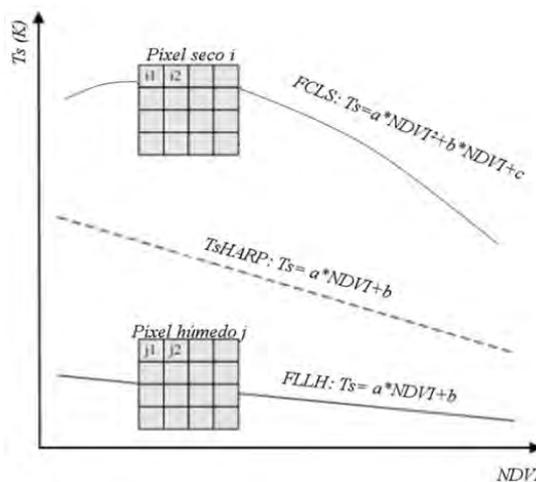


Figura 4.1: Identificación de límites en el espacio NDVI -  $T_s$ .

En la Figura 4.1 el límite seco está representado por la línea llena superior (FCLS), el límite húmedo está representado por la línea llena inferior (FLLH) y la línea punteada central representa la función de regresión utilizada en el modelo  $T_s$ HARP.

En base a lo indicado en la Figura 4.1, se identificó el límite seco por medio de un ajuste cuadrático de los valores de  $T_s$  y de NDVI de las imágenes a baja resolución. A partir de esta función, el modelo queda expresado como:

$$T_{s\text{Baja}}^*(NDVI_{\text{Baja}}) = a (NDVI_{\text{Baja}})^2 + b (NDVI_{\text{Baja}}) + c \quad (4.1)$$

Donde,  $T_{s\text{Baja}}^*(NDVI_{\text{Baja}})$ <sup>8</sup> es la temperatura estimada a partir de la ecuación cuadrática extraída del ajuste de los píxeles que representan el límite seco aplicada a la imagen de NDVI a baja resolución. Los parámetros del ajuste cuadrático están representados por las letras a, b y c. Como esta ecuación refleja únicamente condiciones promedio despreciando la proporción de agua contenida en plantas y suelo, se incorpora la variabilidad producida por el efecto de la humedad del suelo por medio de la siguiente ecuación:

$$\Delta t = T_{s\text{Baja}} - T_{s\text{Baja}}^* \quad (4.2)$$

Donde,  $\Delta t$  es la diferencia o residual resultante de la diferencia entre la temperatura observada ( $T_{s\text{Baja}}$ ) y la temperatura estimada  $T_{s\text{Baja}}^*$ .

La  $T_s$  a alta resolución es estimada a partir de la siguiente expresión:

$$T_s^*FCLS = a (NDVI_{\text{Alta}})^2 + b (NDVI_{\text{Alta}}) + c + \Delta t \quad (4.3)$$

Donde,  $T_s^*FCLS$  es la  $T_s$  de alta resolución, a, b y c son los parámetros resultantes de la función cuadrática resultando de la identificación del límite seco en el diagrama NDVI -  $T_s$ ,  $NDVI_{\text{Alta}}$  es la imagen de NDVI a alta resolución espacial, ( $\Delta t$ ) es la fracción residual de la temperatura que representa la variación de humedad del suelo.

---

<sup>8</sup> el símbolo del asterisco (\*) representa a la imagen de  $T_s$  estimada o simulada.

#### **4.1.2. MODELO DE DIFERENCIA DE LÍMITES.**

El modelo de diferencia de límites se presenta como una alternativa al modelo basado en la función cuadrática del límite seco (FCLS) (Fig. 4.1). Este modelo sigue el mismo flujo metodológico que el aplicado para el FCLS, pero toma en cuenta el límite seco y húmedo del espacio NDVI-T<sub>s</sub>. La T<sub>s</sub> a alta resolución (*T<sub>s</sub>\*Dif.Límites*) se sustenta sobre la diferencia entre las temperaturas modeladas a partir de las funciones del límite seco (FLCS) y húmedo (FLLH). El modelo queda expresado como:

$$T_s^*Dif.Límites = (a (NDVI_{Alta})^2 + b (NDVI_{Alta}) + c) + \Delta t + \Delta L \quad (4.4)$$

Donde,  $\Delta L$  es la diferencia de T<sub>s</sub><sup>\*</sup> entre los límites húmedo y seco ( $T_s^*FLLH - T_s^*FCLS$ ).

#### **4.1.3. MODELOS BASADOS EN ÍNDICES DE ESTRÉS HÍDRICO**

Como se referencia en el *capítulo 2*, el modelo T<sub>s</sub>HARP tiene limitaciones inherentes a la relación NDVI - T<sub>s</sub>. En tal sentido, el modelo T<sub>s</sub>HARP no toma en consideración el hecho de que para un valor determinado de NDVI pueden existir dos lecturas de T<sub>s</sub>. Para eliminar esta limitación del modelo original y obtener mayor variabilidad en la T<sub>s</sub>, incorporando la humedad de superficie, se proponen modelos de remuestreo que toman en cuenta índices de estrés hídrico. Los fundamentos teóricos de los índices de estrés hídrico aplicados en este trabajo fueron explicados en el *capítulo 2*.

El argumento físico que sustenta la incorporación de índices de estrés hídricos en el modelo de remuestreo de datos térmicos es presentado en la Figura 4.2. En la Figura 4.2 (a) se indica la dispersión de la variable T<sub>s</sub> vs. NDVI para un conjunto de 74.000 píxeles para la imagen MODIS del 23/02/2010 a 1 km de resolución espacial. Dentro de esta nube de puntos se seleccionó dos conjuntos de datos con el mismo intervalo de NDVI y diferentes valores de T<sub>s</sub>. En la Figura 4.2 (b) se presenta la nube de dispersión de la T<sub>s</sub> vs. NDWI, donde se puede observar que los píxeles para el intervalo seleccionado de NDVI de la Figura 4.2 (a) son representados en el diagrama NDWI - T<sub>s</sub> con diferentes valores de NDWI (Fig. 4.2 b).

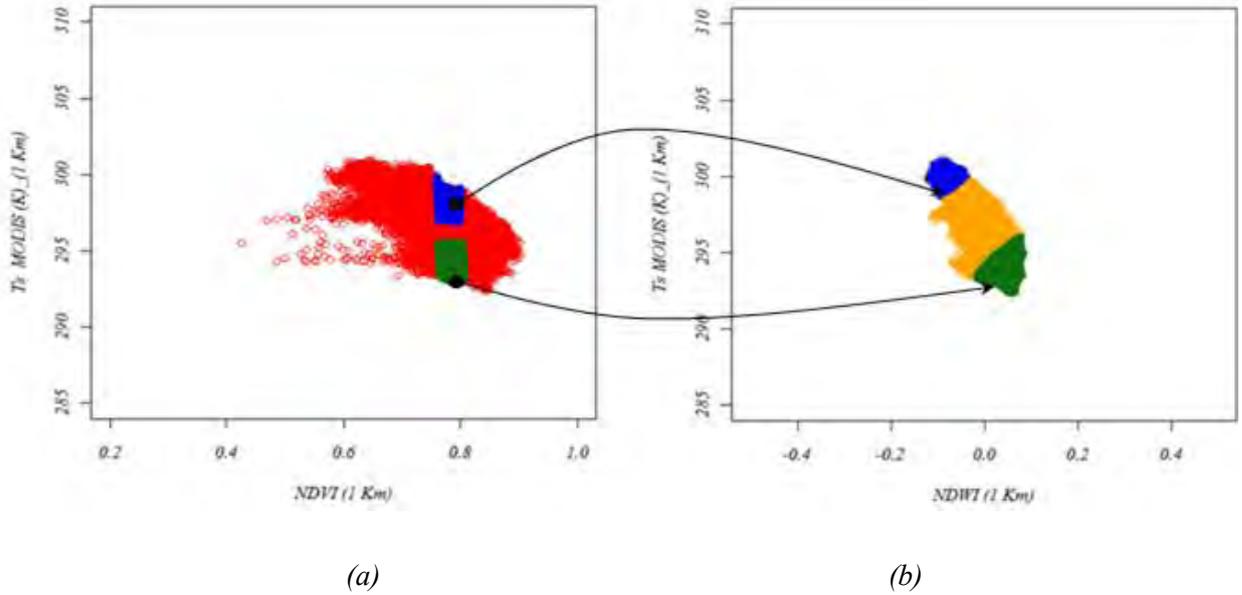


Figura 4.2: a)  $T_s$  vs. NDVI, b)  $T_s$  vs. NDWI.

La formulación matemática de los modelos que integran los índices de EH está basada en el modelo FCLS (Ec. 4.3), la diferencia de límites ( $\Delta L$ ) y la función de cada índice de estrés. Entonces, la  $T_s^*$  a alta resolución en función del NDVI para los diferentes índices de EH queda expresada como:

$$T_s^*NDWIharp = T_s^*(FCLS) + \Delta L * \frac{NDWI - NDWI_{min}}{NDWI_{max} - NDWI_{min}} \quad (4.5)$$

$$T_s^*NDIharp = T_s^*(FCLS) + \Delta L * \frac{NDI - NDI_{min}}{NDI_{max} - NDI_{min}} \quad (4.6)$$

$$T_s^*GVMIharp = T_s^*(FCLS) + \Delta L * \frac{GVMI - GVMI_{min}}{GVMI_{max} - GVMI_{min}} \quad (4.7)$$

$$T_s^*SWIharp = T_s^*(FCLS) + \Delta L * \frac{Ts_{max} - Ts}{Ts_{max} - Ts_{min}} \quad (4.8)$$

Con el propósito de establecer un punto de partida en la evaluación y validación de los modelos de remuestreo, se realizó una rutina de agregación (remuestreo hacia resoluciones más groseras) y disgregación (remuestreo hacia resoluciones finas) de los datos térmicos. La rutina consistió en remuestrear los píxeles originales de 1 km a una resolución espacial de 4 km a través de interpolación de datos espaciales basada en un algoritmo no adaptativo (*Nearest Neighbor*). Por lo tanto, se consideró a la imagen de resolución espacial de 4 km como la imagen base (resolución baja), y a la imagen de 1 km como la imagen a estimar (resolución alta) (Fig. 4.3). La imagen de

temperatura estimada  $[T_{s(1km)}^*]$  fue comparada con la temperatura observada  $[T_{s(1km)}]$ . Los pasos metodológicos para la IS MODIS (23/02/2010) son indicados en el siguiente flujograma.

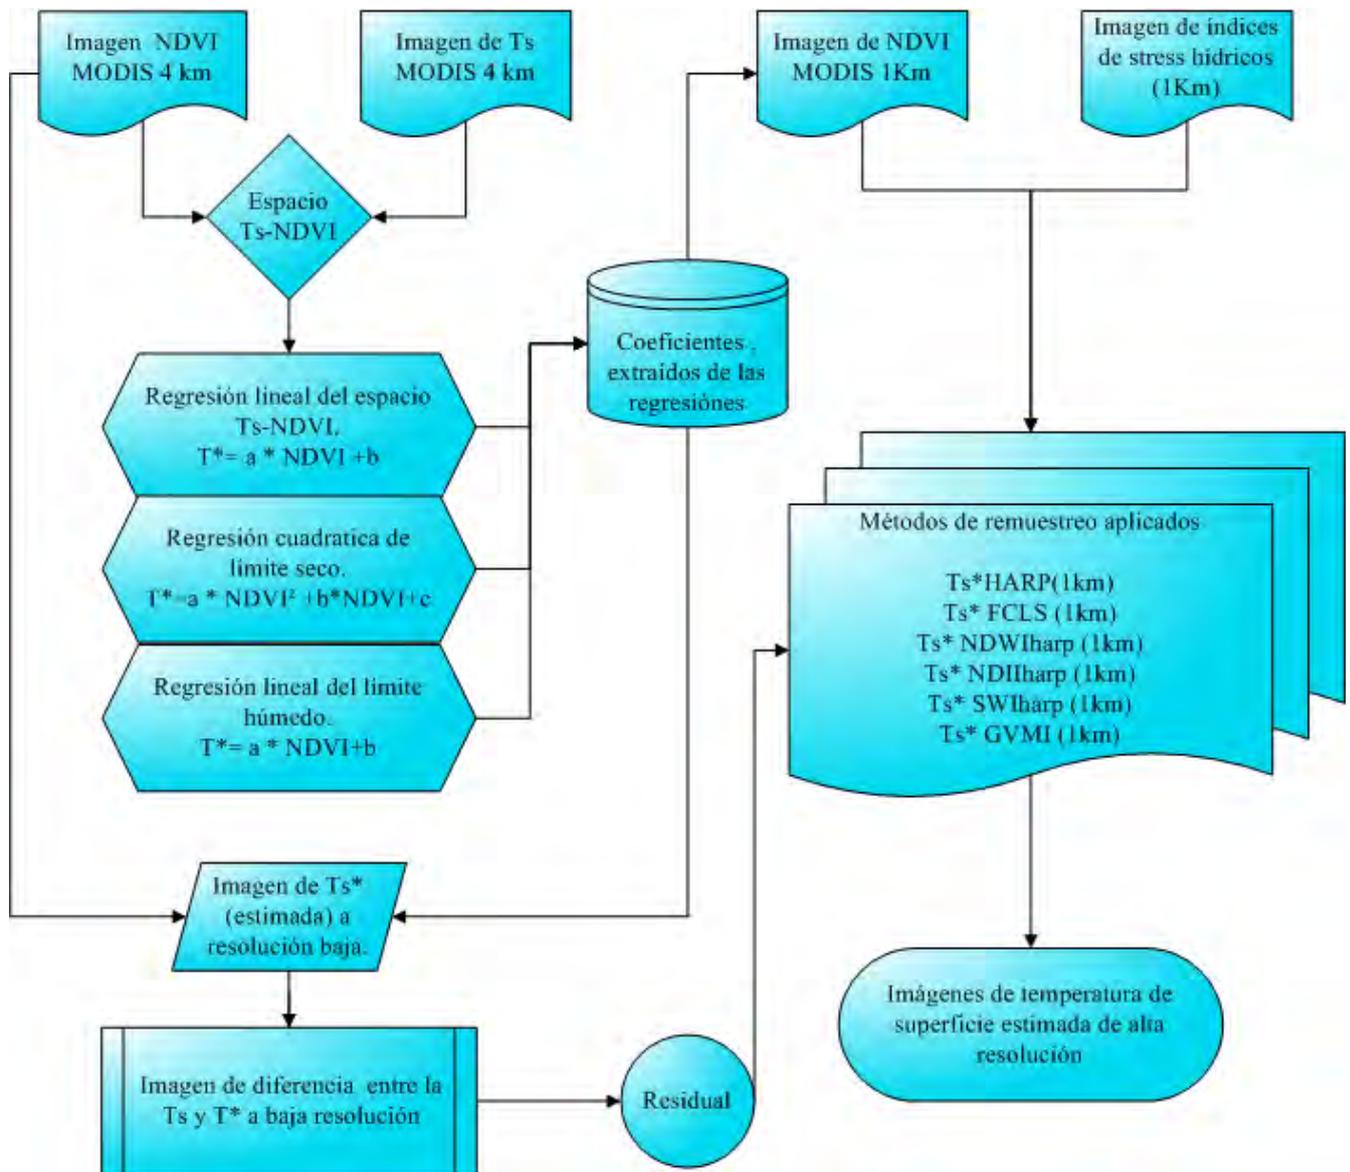


Figura 4.3: Esquema metodológico de remuestreo en imágenes MODIS.

## 4.2. EVALUACIÓN ESTADÍSTICA DE LOS MODELOS PLANTEADOS

Para identificar los patrones de errores espaciales son propuestas dos aproximaciones diferentes. La primera, basada en herramientas de análisis espacial (semivariograma) y estadísticos ( $R^2$ , RMSE, MBE, d, Skewness y Curtosis) programados en el software estadístico R (*R Development Core Team, 2010*) (*Ver Anexo I*). La segunda aproximación, se basa en la validación *in situ* por medio de datos térmicos provistos por la EBE.

Para realizar la caracterización estadística de los resultados obtenidos se utilizaron descriptores estadísticos mínimo, máximo, rango, mediana, media aritmética y desvío estándar. Los estadísticos de skewness y curtosis se utilizaron para describir la forma y distribución de los datos estadísticos.

El grado de relación entre los modelos se determinó por medio de análisis de regresión simple, donde la bondad de ajuste de los métodos se puso en términos del coeficiente de determinación ( $R^2$ ). El  $R^2$  expresa la proporción de varianza de la variable dependiente ( $T_s$  estimada) que está explicada por la variable independiente ( $T_s$  observada) y se expresa como:

$$R^2 = \frac{[\sum(E_i - \bar{E})(O_i - \bar{O})]^2}{\sum(E_i - \bar{E})^2 \sum(O_i - \bar{O})^2} \quad (4.10)$$

Donde,  $O_i$  es el valor observado,  $E_i$  es el valor estimado o modelado.

El error típico de la estimación es un estadístico que complementa al coeficiente de determinación en la interpretación de los resultados obtenidos por el análisis de regresión. Representa la desviación típica de las distancias existentes entre las puntuaciones de la variable dependiente y los pronósticos efectuados por la recta de regresión. Este parámetro es inversamente proporcional al coeficiente de determinación e indica la variabilidad de la variable dependiente que no es explicada por la recta de regresión.

Por otro lado, se utilizó el coeficiente de variación ( $CV$ ), la raíz cuadrada del error cuadrático medio (RMSE), el error relativo (RE), y el índice de concordancia de *Willmott (d, Willmott, 1981)* como herramienta estadística suplementaria para evaluar la precisión de los modelos. Estos estadísticos se expresan como:

$$CV = \left(\frac{\sigma}{\bar{X}}\right) * 100 \quad (4.11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - E_i)^2}{N}} \quad (4.12)$$

$$RE = \frac{RMSE}{\sigma} \quad (4.13)$$

$$ME = \frac{\sum_{i=1}^N (O_i - E_i)}{N} \quad (4.14)$$

$$d = 1 - \frac{\sum_{i=1}^N (O_i - E_i)^2}{\sum_{i=1}^N (|E_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (4.15)$$

Donde, N es el número de observaciones,  $O_i$  es el valor observado,  $E_i$  es el valor estimado o modelado y  $\sigma$  es el desvío estándar,  $\bar{X}$  es la media aritmética.

El cociente entre el error medio cuadrático y el desvío estándar ( $RMSE/\sigma$ ) nos brinda información acerca de eficiencia en la agregación, donde valores cercanos a 1 representa pobre agregación entre las variables y valores menores a 0,5 indica que el valor estimado tiene una agregación satisfactoria con respecto a los valores observados (*Kustas et al., 2003*). Tomando en consideración este parámetro y los estadísticos citados, el modelo fue considerado bueno cuando el  $R^2 \geq 0,80$ ,  $d \geq 0,95$ ,  $RE \leq 0,20$ , y la pendiente de la recta (b) es cercana a 1 ( $1 \pm 0,1$ ) (*Cai et al., 2007; Stockle et al., 2004*).

La resolución original de la  $T_s$  fue mantenida y utilizada como dato de referencia para la validación de las imágenes térmicas estimadas. La desviación de los datos estimados con respecto a los datos observados se evaluó a través del error medio relativo (ME) y es usado para estimar los BIAS de la imagen simulada observando si los modelos subestimaron (valor de ME negativo) o sobreestimaron (valor de ME positivo).

También resulta de interés analizar el histograma de frecuencias de cada modelo de remuestreo (número de píxeles que se cuenta para un determinado valor de temperatura). Varios autores han puesto de relieve el interés del histograma para realizar una primera valoración de la imagen (*Jensen, 1996; Chubieco Salinero, 2008*). En tal sentido, la naturaleza del error en la distribución fue evaluada en términos del estadístico skewness y la curtosis, indicando si el error en la estimación es sistemático o aleatorio. El estadístico skewness (Sk) da una medida de la asimetría de la frecuencia de la distribución de los datos con respecto a la media, cuando la distribución de los datos es simétrica el valor de skewness es igual a 0, cuando este valor es positivo significa que la distribución tiene un corrimiento hacia la derecha, y cuando es negativo el corrimiento es producido en sentido izquierdo. El skewness puede ser expresado de la siguiente manera:

$$Sk = \frac{1}{N} \sum_{i=0}^{N-1} \left( \frac{X_i - \bar{X}}{\sigma} \right)^3 \quad (4.16)$$

La Curtosis (Ct) da una medida de la forma de la frecuencia de distribución de los datos. La distribución de los datos es normal cuando el valor de la curtosis es igual a 0, cuando la curtosis es positiva tiene la mayor frecuencia de distribuciones cercanas a la media aritmética y colas finas. Cuando la curtosis es negativa tiene la frecuencia de distribución baja cercana a la media y colas anchas (Kaps y Lanberson, 2004).

$$Ct = \frac{1}{N} \sum_{i=0}^{N-1} \left( \frac{X_i - \bar{X}}{\sigma} \right)^4 - 3 \quad (4.17)$$

Donde,  $\sigma$  es el desvió estándar,  $\bar{X}$  es la media aritmética,  $X_i$  conjunto de datos de la variable estudiada.

La técnica de semivariograma puede ser utilizada para identificar cambios espaciales, permitiendo diferenciar alteraciones en variables biofísicas ante una determinada perturbación. Esta técnica geoestadística permite identificar puntos de distancia física donde el valor de la variable  $T_s$  consigue la independencia estadística. Esta técnica se basa en el cálculo de la semivarianza, la cual es útil para medir la asociación de una variable a distancias crecientes, mostrando que tan parecido son los puntos en el espacio a medida que éstos se encuentran más alejados, partiendo del supuesto de que los rasgos de la cubierta terrestre se asemejan entre sí cuando más próximos se encuentran. A medida que la separación física entre dos puntos aumenta, la correlación entre ambos puntos tenderá a desaparecer. Esta distancia entre máxima y mínima correlación se llama rango.

Por otra parte, la autocorrelación espacial entre puntos del espacio no es igual en todas direcciones. En este aspecto, el semivariograma no es sólo función de la distancia, sino también de la dirección en la que la distancia crece. Para la estimación del intervalo o distancia mínima se procedió a la identificación visual del rango de cada semivariograma, en el mismo es indicado el punto de decrecimiento de la función donde la variable encuentra la independencia espacial.

La semivarianza puede ser expresada por medio de la siguiente expresión:

$$Semivarianza = \frac{[\sum (X_i Z_i h)^2]}{2Nh} \quad (4.18)$$

Donde,  $X_i$  es la variable medida en un punto,  $Z_i h$  es la variable medida en un sitio desplazado la distancia  $h$  con respecto al sitio  $i$ .  $h$  es el intervalo o distancia entre dos datos y  $N$  es el número de pares de datos, siendo la sumatoria sobre todos los pares de datos.

### **4.3. PROCESAMIENTO DE IMÁGENES DE SATELITE**

#### **4.3.1. IMAGEN LANDSAT**

En esta sección se describen las técnicas y pasos metodológicos que se aplicaron sobre la imagen Landsat 5 TM. Para la corrección radiométrica de la imagen del sensor Thematic Mapper se utilizó un conjunto de técnicas de sencilla implementación basado en la utilización de coeficientes de calibrado para cada canal del sensor para obtener los datos de la imagen en magnitud física y posteriormente en reflectividad. Finalmente se aplicó un algoritmo monocanal para la estimación de la  $T_s$ .

##### **4.3.1.1. CORRECCIÓN RADIOMÉTRICA**

La resolución radiométrica de un sensor es la capacidad para detectar variaciones en la radiancia espectral que recibe (*Chuvienco et al., 2008*). Los valores de los píxeles en las imágenes de satélite expresan la cantidad de energía radiante recibida por el sensor en la forma de valores relativos no calibrados llamados Números Digitales (ND). El sensor TM ofrece la posibilidad de discriminar 256 niveles de grises ya que codifica en 8 bits, generando un conjunto de valores discretos que oscilan entre 0 y 255.

La corrección radiométrica implica la transformación de los valores de DN de la imagen a radiancia TOA y posteriormente a reflectividad. La transformación de los ND a radiancia se basa en una función lineal de los valores de ND usando la ecuación (4.19) (*Schroeder et al., 2006; Chander et al., 2007 y 2009*).

$$L_{\lambda sat} = G_{\lambda} * ND + B_{\lambda} \quad (4.19)$$

Donde,  $L_{\lambda sat}$  es la radiancia espectral de cada banda medida por el sensor al tope de la atmósfera ( $W m^{-2}sr^{-1}\mu m^{-1}$ ), ND es el número digital,  $B_{\lambda}$  es el factor de reescalado de offset o pérdida específica del sensor para cada banda ( $W m^{-2}sr^{-1}\mu m^{-1}$ ),  $G_{\lambda}$  es el factor de reescalado de la ganancia específica del sensor para cada banda ( $W m^{-2}sr^{-1}\mu m^{-1}/ND$ ) (*Chander y Markham, 2003; Chander et al., 2007*). El efecto de la degradación del sensor sobre el parámetro de ganancia ( $G_{\lambda}$ ) fue considerado usando los coeficientes de *Chander et al., (2007)*. Los valores de coeficientes de calibrado utilizados para la corrección radiométrica de las imágenes Landsat TM se muestran en el [Anexo II. Tabla 1.](#)

Por otra parte, las variaciones geográficas y temporales pueden ser muy altas cuando se comparan imágenes de diferentes sensores (*Liang et al., 2002*). En tal sentido, *Chander et al., (2007)* expresa que es conveniente utilizar la reflectancia a TOA, ya que remueve el efecto de los diferentes ángulos cenitales provocados por diferencias entre tiempo de adquisición de los datos, compensa las diferencias espectrales entre bandas corrigiendo los valores de irradiancia exoatmosférica y corrige la variación de la distancia tierra-sol entre datos con diferente tiempo de adquisición.

La conversión de radiancia a reflectividad aparente TOA se realizó utilizando la ecuación (4.20), asumiendo una superficie Lambertiana bajo condiciones libre de nubes sin considerar efectos atmosféricos.

$$\rho_{\lambda} = \frac{\pi L_{\lambda sat}}{E_{\lambda 0} d^{-2} \cos \theta_z} \quad (4.20)$$

Donde,  $\rho_{\lambda}$  es la reflectancia TOA,  $\pi$  constante matemática adimensional aproximada a 3,14159 que representa la asunción de una superficie Lambertiana,  $L_{\lambda sat}$  es la radiancia espectral para cada banda a TOA,  $E_{\lambda 0}$  es la irradiancia solar espectral exoatmosférica ( $W m^{-2} \mu m^{-1}$ ),  $d$  es la distancia Tierra-sol medida en unidades astronómicas (UA) y  $\theta_z$  es el ángulo cenital solar.

La distancia tierra-sol se estimó siguiendo la ecuación propuesta por *Wainschenker et al., (2008)*.

$$d = 1 - 0,01673 * \cos\left(2\pi * \frac{\text{dia Juliano}-3}{365}\right) \quad (4.21)$$

Las constantes de irradiancia solar espectral exoatmosférica utilizadas en el cálculo de la reflectividad aparente se muestran en el [Anexo II. Tabla 2](#).

#### 4.3.1.2. CORRECCIÓN ATMOSFÉRICA

Se realizó la corrección atmosférica de los canales visibles e infrarrojo cercano (bandas 1-4 de Landsat TM) convirtiendo la reflectividad TOA a reflectividad de superficie, asumiendo superficie Lambertiana en zonas de planicie con condiciones libres de nubes. Siguiendo la ecuación 4.22 se corrigieron los efectos atmosféricos (*Schroeder et al., 2006; Barnaby et al., 1010*).

$$\rho_{\lambda(\text{sup})} = \frac{\pi(L_{\lambda sat} - L_{\lambda p})}{T_{\lambda v} * (E_{\lambda 0} d^{-2} \cos \theta_z T_{\lambda z} + E_{\lambda l})} \quad (4.22)$$

Donde,  $L_{\lambda p}$  es la radiancia registrada resultante de la interacción entre la radiación electromagnética (EM) con los gases y polvos atmosféricos expresada en  $W m^{-2} sr^{-1} \mu m^{-1}$ ,  $T_{\lambda v}$  es la transmisividad

atmosférica desde la superficie hacia el sensor,  $T_{\lambda z}$  es la transmisividad atmosférica en la dirección de la iluminación solar,  $E_{\lambda \downarrow}$  es la irradiancia difusa desde la atmósfera hacia la superficie ( $\text{W m}^{-2} \mu\text{m}^{-1}$ ), y  $\cos \theta_z$  es el coseno del ángulo solar cenital (grados).

Para la región del espectro correspondiente al infrarrojo medio (bandas 5 y 7 de Landsat TM), la atmósfera no introduce efectos significativos. Por lo tanto, es válido aplicar la ecuación (4.20) para estimar la reflectividad de la superficie.

Se utilizó el método de sustracción de superficies oscuras (*DOS o Dark Object Subtraction*) para realizar la corrección atmosférica de la imagen, por medio de la estimación de los parámetros  $E_{\lambda \downarrow}$ ,  $L_{\lambda p}$ ,  $\tau_{\lambda z}$  y  $\tau_{\lambda v}$  (Chávez, 1989; Teillet & Fedosejevs, 1995; Santer et al., 1999; Schroeder et al., 2006) (Fig. 4.4).

Este método asume que en la escena de la IS existen zonas oscuras con reflectividades porcentuales cercanas a cero (por ejemplo: agua clara y profunda, bosque denso y sombras). Por lo tanto, la señal recibida por el sensor desde un objeto oscuro es considerada el excedente producido por la dispersión atmosférica o scattering (Chavez, 1989-1996; Song et al., 2001; Schroeder et al., 2006, Barnaby et al., 2010). Considera también una atmósfera Rayleigh sin aerosoles y una reflectividad de 1 % para coberturas oscuras (segundo término de la ecuación 4.23) en las longitudes de ondas del azul, verde y roja.

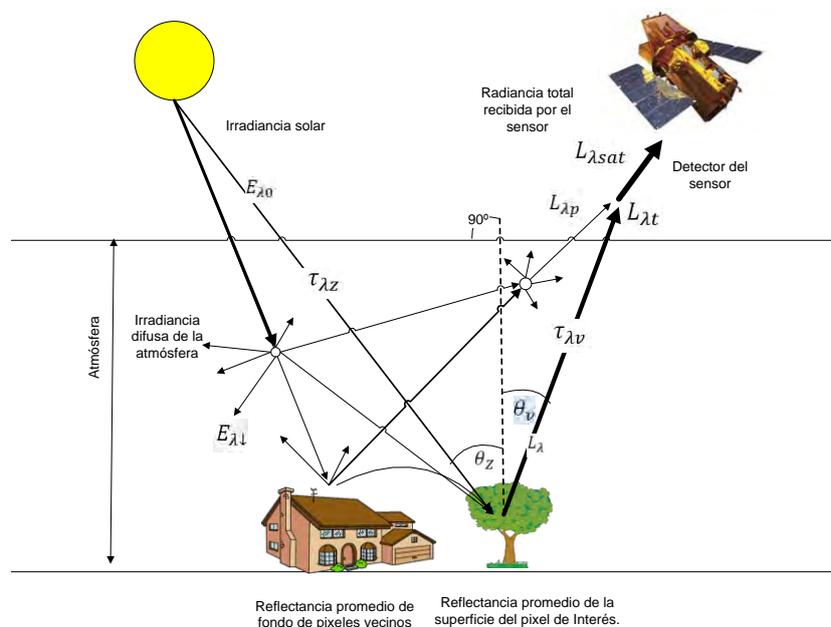


Figura 4.4: Radiancia recibida por el sensor remoto e interacciones atmósfera - energía EM (modificado de Jensen, 1996).

La radiancia reflejada en cada píxel estimado ( $L_{\lambda i}$ ) está representada por la diferencia entre  $L_{\lambda sat}$  y  $L_{\lambda p}$ . En tal sentido, esa proporción residual de reflectividad introducida por la atmósfera es removida (Fig. 4.4). La radiancia  $L_{\lambda p}$  se estima usando la expresión:

$$L_{\lambda p} = L_{DOS} - 0.01 \left( \frac{E_{\lambda 0} \cos \theta_s T_{\lambda z} T_{\lambda v}}{d^2 \pi} \right) \quad (4.23)$$

Donde  $L_{DOS}$  es el valor de radiancia mínimo de la superficie oscura para cada banda espectral de una región de interés de al menos 1000 píxeles (Teillet y Fedosejevs, 1995, Carmona y Rivas, 2010, Barnaby et al., 2010). Por otra parte, Schroeder et al. (2006) estableció por medio de una evolución de rendimiento del método DOS en imágenes de satélite ópticas en bandas del visible e infrarrojo una precisión de  $\pm 0,02 \text{ Wm}^{-2}\text{sr}^{-1}\mu\text{m}^{-1}$ . Coincidentemente con los resultados obtenidos con otros autores, los valores de  $\rho_{\lambda}$  obtenidos con el método DOS presentan un error relativo aproximado de 10 % (Liang et al., 2002; Barnaby et al., 2010).

Para realizar los cálculos sobre la imagen se aplicó la ecuación equivalente a la 4.22 expresada como:

$$\rho_{\lambda} = \frac{(\rho_{\lambda} - \rho_{\lambda min} + 0.01)}{T_{\lambda z} T_{\lambda v}} \quad (4.24)$$

Donde,  $\rho_{\lambda}$  y  $\rho_{\lambda min}$  son la reflectividad TOA y la reflectividad de una superficie oscura respectivamente,  $\tau_{\lambda v}$  es la transmisividad de la atmósfera dependiente del ángulo de observación del sensor y  $\tau_{\lambda z}$  transmisividad atmosférica dependiente del coseno del ángulo cenital solar, determinándose de la siguiente manera:

$$\tau_{\lambda v} = e^{-\frac{\tau_{\lambda r}}{\cos(\theta_v)}} = 1 - \frac{4\pi L_p}{E_0 \cos \theta_v} \quad (4.25a)$$

$$\tau_{\lambda z} = e^{-\frac{\tau_{\lambda r}}{\cos(\theta_z)}} = 1 - \frac{4\pi L_p}{E_0 \cos \theta_z} \quad (4.25b)$$

La forma de adquisición de datos para el sensor TM es a nadir, siendo 0 el ángulo cenital del sensor ( $\theta_v$ ).

Finalmente, el espesor óptico para la dispersión de Rayleigh ( $\tau_{\lambda r}$ ) (Kaufman et al., 1989) fue estimado considerando la longitud de onda efectiva para cada banda ( $\lambda_m$ ) (Ver Anexo II. Tabla 3) a partir de la siguiente expresión:

$$\tau_{\lambda r} = 0,008569 \lambda_m^{-4} (1 + 0,0113 \lambda_m^{-2} + 0,00013 \lambda_m^{-4}) \quad (4.26)$$

Para realizar la corrección por el método DOS de las IS Landsat se seleccionó una región de interés (ROI) de las IS Landsat 5 TM perteneciente a *path 227 row 86* de la misma fecha. Se calculó el estadístico de la zona oscura perteneciente a una zona de mar y se tomaron las reflectividades mínimas, que posteriormente fueron usadas para la corrección de la imagen de interés.

#### 4.3.1.3. ESTIMACION DE $T_s$ USANDO ALGORITMO MONOCANAL

Los datos térmicos (banda 6 en sensor TM) en forma de radiancia fueron convertidos a temperatura de brillo efectiva por medio de la ecuación:

$$T_\lambda = \frac{K_2}{\ln\left[\frac{K_1}{L_\lambda} + 1\right]} \quad (4.27)$$

Donde,  $T_\lambda$  es la temperatura de brillo efectiva del satélite en kelvin,  $K_1$  es igual a 607,79 ( $\text{W m}^{-2}\text{sr}^{-1}\mu\text{m}^{-1}$ ),  $K_2$  es igual a 1260,56 Kelvin. (Chander et al., 2009).

La  $T_s$  ha sido calculada a partir de la temperatura de brillo del sensor ( $T_\lambda$ ) aplicando el algoritmo monocanal propuesto por Jiménez-Muñoz y Sobrino (2003):

$$T_s = \gamma[\varepsilon^{-1} (\psi_1 L_{sensor} + \psi_2) + \psi_3] + \delta \quad (4.28)$$

El  $\gamma$  se estima a partir de:

$$\gamma = \left\{ \frac{C_2 L_{sensor}}{T_{sensor}^2} \left[ \frac{\lambda_{ef}^4}{C_1} L_6 + \lambda_{ef}^{-1} \right] \right\}^{-1} \quad (4.29)$$

Donde  $\delta$  se obtiene por medio de:

$$\delta = -\gamma L_{sensor} + T_{sensor} \quad (4.30)$$

Siendo,  $L_{sensor}$  es la radiancia registrada por el sensor TM en el canal 6 ( $\text{W m}^{-2}\text{sr}^{-1}\mu\text{m}^{-1}$ ),  $T_{sensor}$  es la temperatura de brillo (K),  $\lambda_{ef}$  es la longitud de onda efectiva (11,457  $\mu\text{m}$ ),  $C_1$  y  $C_2$  son constantes universales ( $1,19104 \cdot 10^8 \text{ W } \mu\text{m}^4 \text{ m}^{-2} \text{ sr}^{-1}$  y  $1,43877 \cdot 10^4 \mu\text{m K}$  respectivamente).

La emisividad de la superficie ( $\varepsilon$ ) se estimó en función al porcentaje de vegetación ( $Pv$ ), la emisividad de la vegetación y suelo desnudo (Valor y Caselles, 1996; Rivas y Caselles, 2004).

$$\varepsilon_s = \varepsilon_v P_v + \varepsilon_{su}(1 - P_v) \quad (4.31)$$

Donde  $\varepsilon_v$  es la emisividad de la vegetación y  $\varepsilon_s$  es la emisividad del suelo (0,985 y 0,96 respectivamente).

La determinación del porcentaje de vegetación ( $P_v$ ) se obtuvo a partir de la ecuación de *Carlson y Ripley (1997)* siendo:

$$P_v = \left[ \frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right]^2 \quad (4.32)$$

Donde,  $NDVI_{min}$  representa a los valores de los NDVI del suelo desnudo y  $NDVI_{max}$  representa a los valores de los NDVI de la vegetación sana (cobertura vegetal total).

Las funciones atmosféricas  $\psi_1$ ,  $\psi_2$  y  $\psi_3$  fueron obtenidas como función del contenido de vapor de agua total (W) de la atmósfera expresado en  $gr\ cm^{-2}$  (*Jiménez-Muñoz y Sobrino, 2003*). El valor de W está considerado en base a un promedio entre las mediciones de los radiosondeo del observatorio aéreo Ezeiza, Buenos Aires ( $34^{\circ}49'S$ ,  $58^{\circ}32'W$ ) y Santa Rosa, La Pampa ( $36^{\circ}34'S$ ,  $64^{\circ}16'W$ ), Argentina. Las mediciones del contenido de vapor de agua total de la atmósfera fueron realizadas a las 12 UTC (*University of Wyoming, Department of Atmospheric Science, <http://wather.uwyo.edu>*).

$$\psi_1 = 0,14714 w^2 - 0,15583 w + 1,1234 \quad (4.33a)$$

$$\psi_2 = -1,1836 w^2 - 0,37607 w + 0,52894 \quad (4.33b)$$

$$\psi_3 = 0,04554 w^2 - 1,8719 w + 0,39071 \quad (4.33c)$$

#### **4.3.2. IMÁGENES MODIS TERRA**

En este trabajo se utilizaron imágenes del sensor MODIS Terra adquirida en la estación terrena de Teófilo Tabanera perteneciente a la Comisión Nacional de Actividades Espaciales de Argentina (CONAE). Las imágenes utilizadas fueron adquiridas con nivel de procesamiento 1B a diferente resolución espacial ( $1\ km^2$ , 500 y 250 m). Los datos correspondientes al nivel 1B de MODIS contienen 36 bandas en unidades de radiancia TOA a partir del procesamiento del nivel 1A. La  $L_{\lambda sat}$  (reescaladas entre 0 - 32767) se presentan en unidades de  $Wm^{-2}sr^{-1}\mu m^{-1}$  (*MODIS Product User's Guide for Level 1B*).

#### **4.3.2.1. CORRECCIÓN GEOMÉTRICA**

Las imágenes MODIS y Landsat poseen características específicas ya que la adquisición de la imagen se realiza bajo diferentes ángulos de visión y sentido de observación. Por lo tanto, fue necesario ajustar las imágenes a través de una registración para lograr un producto óptimo.

Para llevar a cabo la corrección geométrica correspondiente a un proceso en donde una imagen es trasladada y rotada en el espacio de tal manera que sus elementos coincidan con los de las imágenes de referencia Landsat TM. Para esto se utilizó una serie de puntos de control (GCPs) tomados entre las imágenes hasta lograr un número que osciló entre 25 y 30 puntos en función de un umbral definido por 1 píxel de error. Los puntos de control se colocaron en rasgos antrópicos del paisaje, de forma uniforme y ajustando las coordenadas X e Y de imagen a imagen de referencia.

#### **4.3.2.2. CORRECCIÓN RADIOMÉTRICA**

Para realizar la conversión de la imagen MODIS a magnitud física de radiancia se utilizaron los datos de calibración de la ganancia  $G_\lambda$  y offset ( $B_\lambda$ ) para cada banda que se encuentran en las efemérides del satélite. Esta transformación se realiza a partir de la ecuación (3.34) (*MODIS User Guide, 2003*).

$$L_{\lambda sat} = G_\lambda * (ND - B_\lambda) \quad (3.34)$$

Donde, ND es el valor de la cuenta digital reescalada entre el cero y el máximo valor que puede obtener un píxel (32767) para cada banda espectral considerada.  $G_\lambda$  es el factor de reescalamiento de la ganancia específica del sensor para cada banda ( $W m^{-2}sr^{-1}\mu m^{-1}/ND$ ),  $B_\lambda$  es el factor de reescalamiento de offset o pérdida específica del sensor para cada banda ( $W m^{-2}sr^{-1}\mu m^{-1}$ ).

#### **4.3.2.3. CORRECCIÓN ATMOSFÉRICA**

El método utilizado para la corrección atmosférica fue el método sustracción de superficies oscuras (DOS) descrito en la sección 4.3.1.2, ecuación 4.22. Por medio de las ecuaciones 4.25 (a-b) se determinó  $\tau_{\lambda z}$  y  $\tau_{\lambda v}$  usando los ángulos cenitales promedios para cada imagen. El ángulo de observación del sensor MODIS no se encuentra a nadir. Por lo tanto, para estimar correctamente la  $\tau_{\lambda v}$  el ángulo cenital del sensor debe ser tomado en consideración (producto MOD05 o 09 de MODIS).

Para aplicar este método se usó la información de ángulos cenital - azimuth del sensor y del sol contenida en el producto MOD03 descargado del sitio web MODIS Rapid Response System NASA (<http://rapidfire.sci.gsfc.nasa.gov/realtime/2010054/>).

#### 4.3.2.4. ESTIMACIÓN DE $T_s$ USANDO ALGORITMO SPLIT WINDOW

Las bandas emisivas del sensor MODIS adquieren información en la ventana espectral de 10,780 - 11,280  $\mu\text{m}$  y 11,770 - 12,270  $\mu\text{m}$  respectivamente (bandas 31 y 32 del formato 1B).

Se utilizó la función equivalente a la inversa a la *Ley de Planck* para realizar la conversión de radiancia a temperatura radiativa al tope de la atmosfera (TOA) teniendo en consideración la longitud de onda efectiva de los canales térmicos de la imagen MODIS. La función inversa a la *Ley de Planck* está expresada como:

$$T_{31} = \frac{14388}{11,025 * \log\left(1 + \frac{1,1911 * E08}{(11,025)^5 * L_{31}}\right)} \quad (4.35a)$$

$$T_{32} = \frac{14388}{12,029 * \log\left(1 + \frac{1,1911 * E08}{(12,029)^5 * L_{32}}\right)} \quad (4.35b)$$

Donde,  $L_{31}$  y  $L_{32}$  son los valores de radiancia de las bandas 31 y 32 respectivamente. Las longitudes de onda efectiva de las bandas 31 y 32 están representadas por los valores 11,025 y 12,029 ( $\mu\text{m}$ ) respectivamente.

La  $T_s$  fue calculada a partir de la temperatura de brillo de la banda 31 y 32 utilizando algoritmo Split Window desarrollado por *Coll et al. (2005)*. Este es un método de absorción diferencial que utiliza dos canales dentro de una misma ventana atmosférica ubicada entre 10 y 12,5  $\mu\text{m}$ , obteniendo similares procesos de absorción y emisión atmosférica. Por tanto, consigue una buena correlación entre la corrección atmosférica en un canal y la absorción diferencial entre las dos bandas. Entonces, a partir de la diferencia de temperaturas obtenidas en los dos canales sobre un mismo píxel es posible determinar la  $T_s$  de superficie por medio de la siguiente ecuación:

$$T_s = T_{31} + [2,41 + 0,432(T_{31} - T_{32})](T_{31} - T_{32}) + 0,359 + \alpha(w)(1 - \varepsilon) + \beta(w)\Delta\varepsilon \quad (4.36)$$

Donde,  $T_s$  es la temperatura de superficie corregida de los efectos atmosféricos (K),  $T_{31}$  y  $T_{32}$  son las temperaturas de brillo para las bandas 31 y 32 de MODIS (K),  $w$  es el contenido de vapor de

agua de la atmósfera en  $\text{g cm}^{-2}$ ,  $\alpha$  y  $\beta$  son parámetros que dependen del contenido de vapor de agua de la atmósfera,  $\varepsilon$  es la emisividad media de la superficie en el intervalo 11,025 - 12,029  $\mu\text{m}$  ( $\varepsilon = \frac{\varepsilon_{31} - \varepsilon_{32}}{2}$ ),  $\Delta\varepsilon$  es la diferencia espectral de emisividad ( $\Delta\varepsilon = \varepsilon_{31} - \varepsilon_{32}$ ).

La determinación de la  $\varepsilon$  para el intervalo del espectro considerado se estimó a partir del método de la cobertura vegetal propuesto por *Valor y Caselles (1996)*, sin considerar el término de cavidad (*Kerdiles et al., 1997; Rivas y Caselles 2004*):

$$E_{31} = 0,985 * P_v + 0,950(1 - P_v) \quad (4.37a)$$

$$E_{32} = 0,985 * P_v + 0,970(1 - P_v) \quad (4.37b)$$

Donde,  $P_v$  es el porcentaje de vegetación, estimado a partir del algoritmo planteado por *Carlson y Ripley (1996)* (ecuación 4.32). El coeficiente de emisividad para la banda 31 en vegetación se encuentra en el orden de 0,985 y 0,950 para suelo desnudo. Por otra parte, para la banda 32 el coeficiente de emisividad está en el orden de 0,985 para vegetación y 0,970 para suelo desnudo.

Los valores de  $\alpha$  y  $\beta$  han sido estimados a partir del contenido de agua de la atmósfera aplicando los siguientes algoritmos:

$$\alpha = 44,1 + 5,4 \frac{w}{\cos(\theta)} - 1,77 \left( \frac{w}{\cos(\theta)} \right)^2 \quad (4.38a)$$

$$\beta = 165,5 - 28,1 \frac{w}{\cos(\theta)} \quad (4.38b)$$

Donde,  $\theta$  es el ángulo de observación del sensor,  $w$  es el contenido de vapor de agua de la atmósfera, disponible en el producto MOD05 de MODIS y se identifica por la banda Water Vapor Near Infrared. Los valores de  $\alpha$  y  $\beta$  dependerán de la temperatura de cada canal de la imagen considerada y de la  $w$  utilizada.

#### **4.3.2.5. GENERACIÓN DE MÁSCARA DE NUBES**

Con el objetivo de eliminar la presencia de nubes se generó una máscara a partir de la banda 26 del sensor MODIS que se encuentra ubicada en el intervalo espectral de 1,36 - 1,39  $\mu\text{m}$ . Esta banda sirve para enmascarar píxeles con nubes a partir de un valor límite de reflectividad, convirtiendo a cero el valor de reflectividad asociado al píxel de la imagen que contenga nubes. La máscara se construyó descartando los valores de  $\rho_{26}$  de 0,006 (*Fig. 4.5 a*). Además, se utilizó el producto

MOD03, específicamente la máscara de océanos, que sirvió para enmascarar los valores de reflectividad del agua (Fig. 4.5 b).

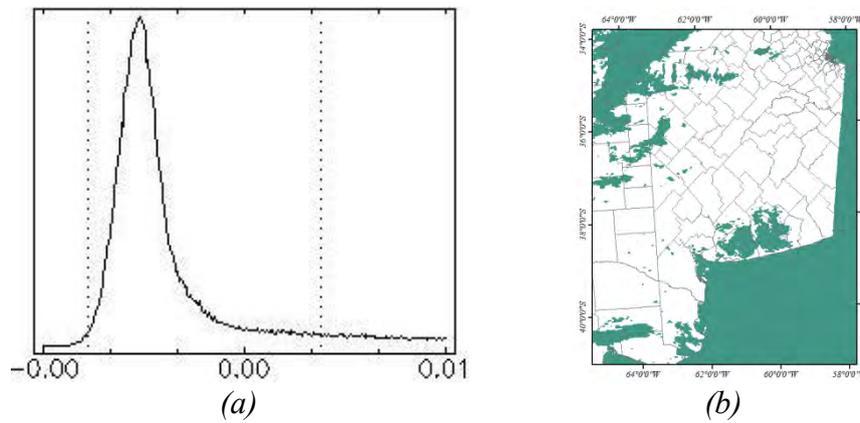


Figura 4.5: a) Histograma de reflectividad de la banda 26 ( $\rho_{26}$ ), b) máscara resultante de la extracción de datos por medio del producto MOD03 y del histograma de  $\rho_{26}$ .

***PARTE III***

***RESULTADOS Y DISCUSIÓN***

## Capítulo V - RESULTADOS OBTENIDOS A PARTIR DE IMÁGENES LANDSAT TM

En esta sección se evaluó y analizó la precisión de los modelos de remuestreo de  $T_s$  a nivel de subpíxel utilizando la imagen del sensor Landsat 5 TM del 23/02/2010 (*Ver Anexo III*). En función a las características específicas del sensor TM, se consideró en el análisis el modelo  $T_s$ HARP, el  $T_s^*$ FCLS, el  $T_s^*$ Dif. de límites, el  $T_s^*$ SWIharp, el  $T_s^*$ NDIIharp, y el  $T_s^*$ GVMIIharp. En término de la información espectral, el sensor TM no posee canal centrado en el intervalo espectral de  $1,24 \mu\text{m}$ , por lo tanto, la implementación del modelo  $T_s^*$ NDWIharp no se consideró.

Los datos originales de la IS Landsat fueron agregados a resoluciones espaciales de 960 m, 740 m y 240 m, con el propósito de validar los modelos propuestos y hacerlos comparables con otros datos de satélite. Para esto se programó una rutina en el lenguaje IDL basada en la interpolación de datos espaciales utilizando diferentes descriptores estadísticos (valores promedio, mediana y desvío estándar), implementada sobre un kernel de 16 píxeles (4 x 4 píxeles) (*Anexo IV*).

La eficiencia de los algoritmos de interpolación en el proceso de agregación se evaluó por medio de un modelo lineal de ajuste considerando las variables  $T_s$  MODIS y Landsat TM a 960 m de resolución espacial.

En la Tabla 5.1 se presenta la precisión global de los métodos de interpolación con el valor del  $R^2$  MODIS - TM. El método de interpolación basado en promedio y mediana indican la mayor correlación entre las variables, con 0,63 y 0,58 respectivamente. Se compararon también con los algoritmos de interpolación de datos disponibles en el software ENVI (Bilinear, Nearest Neighbor, Cubic Convolution), con 35 y 45 % de los datos correlacionados (*Tabla 5.1*).

<i>Imágenes Comparadas</i>	<i>Método de Agregación</i>	<i>R<sup>2</sup></i>
<b>MODIS vs. Landsat 5 TM</b>	<i>Promedio (IDL)</i>	<i>0,63</i>
	<i>Promedio + SD (IDL)</i>	<i>0,52</i>
	<i>Mediana (IDL)</i>	<i>0,58</i>
	<i>Cubic Convolution</i>	<i>0,45</i>
<b>(960 m de resolución)</b>	<i>Nearest Neighbor</i>	<i>0,35</i>
	<i>Bilinear (Envi)</i>	<i>0,35</i>

Tabla 5.1: Comparación imagen MODIS Terra y Landsat 5 TM a 960 m de resolución espacial.

La temperatura estimada de un píxel es el resultado de la cantidad de radiación emitida en el mismo y captada por el sensor. Si el píxel considerado corresponde a la resolución de 1 km, la relación medida dependerá de la temperatura promedio de área considerada (*Girolimetto et al, 2007*).

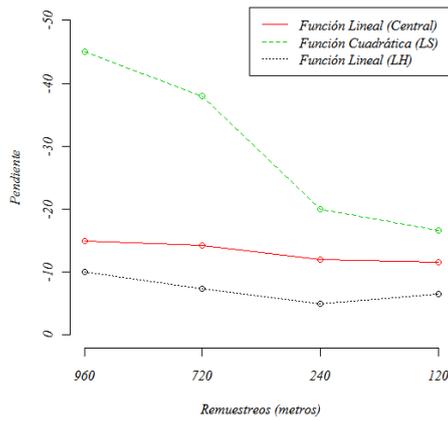
Entonces, es posible pensar que existan dentro del área del píxel variaciones naturales, aún dentro de superficies cuya cubierta vegetal y tipo de suelo varíen gradualmente. El resultado obtenido a partir de la agregación por valores promedios de la imagen Landsat 5 TM consideraría la variabilidad térmica contenida en el píxel de forma promediada, tal como estaría contenida en los píxeles de la imagen MODIS. En base a los resultados obtenidos en la Tabla 5.1, se realizó la agregación de los datos Landsat por medio de la interpolación basada en promedio. Los datos remuestreados a 960 m, 720 m y 120 m fueron los correspondientes a los índices de NDVI, NDII, GVMI y temperatura de superficie de la imagen Landsat 5 TM.

Siguiendo el esquema metodológico planteado en la Figura 4.2 se generaron los espacios NDVI -  $T_s$  para cada una de las resoluciones (960 m, 720 m, 240 m y 120 m) de la IS Landsat. Las funciones obtenidas para la aplicación de los modelos se presentan en la Tabla 5.2. Los modelos de regresión calculados para el conjunto de datos considerados se muestran en el *Anexo V*.

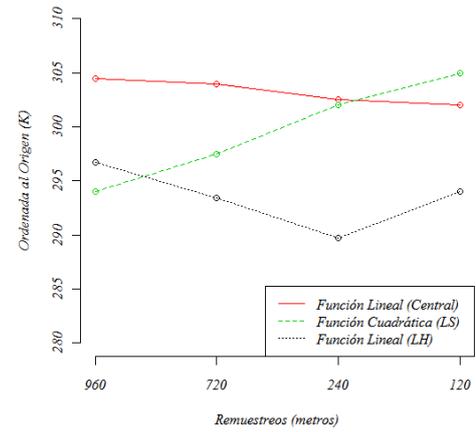
Remuestreo	Función Central	Función Límite Seco	Función Límite Húmedo
<b>Landsat 5 TM (960 m)</b>	$Y = -15,0X + 304,5$	$Y = -45,0X^2 + 36,8X + 294$	$Y = -10,0X + 296,5$
<b>Landsat 5 TM (720 m)</b>	$Y = -14,3X + 304,0$	$Y = -38,0X^2 + 27,5X + 297,5$	$Y = -7,4X + 293,4$
<b>Landsat 5 TM (240 m)</b>	$Y = -12,0X + 302,5$	$Y = -20,0X^2 + 12,0X + 302,0$	$Y = -5,0X + 289,7$
<b>Landsat 5 TM (120 m)</b>	$Y = -11,5X + 302,0$	$Y = -16,6X^2 + 9,0X + 305,0$	$Y = -6,5X + 294,0$

Tabla 5.2: Funciones central, límite seco y húmedo a diferentes resoluciones espaciales.

En la Figura 5.1 se muestran los valores de pendiente y ordenada al origen para los diferentes espacios de NDVI -  $T_s$ . Se observa que los valores de pendiente y ordenada al origen tienden a disminuir al decrecer la resolución espacial para las funciones lineales. Sin embargo, los valores de ordenada al origen para las funciones cuadráticas tienden a incrementarse al disminuir la resolución espacial. Teniendo en cuenta que se utilizaron todos los datos contenidos en las imágenes, los cambios en los parámetros son consecuencia de la heterogeneidad espacial de la muestra considerada. Por lo tanto, es de esperar que los parámetros varíen en mayor proporción para imágenes de menor resolución espacial.



(a)



(b)

Figura 5.1: Comparación entre pendiente y ordenada al origen a diferentes resoluciones espaciales. a) Pendientes de funciones con respecto a la resolución espacial, b) Ordenada al origen de funciones con respecto a la resolución espacial.

La Tabla 5.3 presenta los resultados de los modelos de remuestreo de  $T_s$  para la resolución espacial de 720 m derivados de las funciones de los límites de espacio NDVI -  $T_s$  a 960 m de resolución espacial. Se observa que las estimaciones presentan alto grado de homogeneidad en los valores de rango y media aritmética, indicando que el modelo  $T_s^*$  Dif. de límites y el  $T_s^*$  SWIharp muestran la mayor semejanza con los datos observados, con 19,11 y 19,14 K respectivamente.

Estadísticos	$T_s$ Landsat 5 TM (720 m)	$T_s$ HARP	$T_s^*$ FCLS	$T_s^*$ Dif. de Límites	$T_s^*$ SWIharp	$T_s^*$ NDIIharp	$T_s^*$ GVMiharp
Mínimo (K)	284,1	282,2	284,5	283,1	283,4	280,4	280,7
1er. Cuartil (K)	292,6	292,6	292,6	292,7	292,7	292,8	292,8
Mediana (K)	294,4	294,3	294,2	294,3	294,3	294,3	294,3
Media (K)	294,3	294,3	294,2	294,3	294,3	294,4	294,4
3er. Cuartil (K)	295,8	296,0	295,7	295,8	295,7	295,8	295,8
Máximo (K)	303,6	302,7	302,2	302,2	302,6	306,5	304,8
Rango (máx-mín) (K)	19,55	20,45	17,73	19,11	19,14	26,07	24,13
Desvío estándar (K)	2,36	2,42	2,30	2,27	2,23	2,26	2,22
Coef. Variación (%)	0,80	0,82	0,78	0,77	0,75	0,76	0,75
Skewness	0,12	0,11	0,09	0,14	0,14	0,10	0,09
Curtosis	-0,22	-0,19	-0,32	-0,17	-0,21	0,166	0,101
RMSE (K)		1,00	0,73	0,92	0,73	1,07	0,97
RE (K)		0,0034	0,0024	0,0031	0,0025	0,0036	0,0033
ME (K)		0,0180	-0,097	0,0171	-0,022	0,026	0,048
d		0,95	0,97	0,96	0,97	0,94	0,95
RMSE/ $\sigma$		0,41	0,31	0,40	0,33	0,47	0,44

Tabla 5.3: Estadísticos comparativos entre la imagen de  $T_s$  observada Landsat 5 TM y las estimadas a 720 m de resolución espacial.

Por otro lado, el error promedio evaluado en términos de RMSE y RE indican que los modelos  $T_s^*$  FCLS y  $T_s^*$  SWIharp presentan las menores estimaciones, con 0,73 K y 0,0024 K respectivamente. Además, estos modelos presentan la mejor eficiencia en la agregación de los datos, representada con valores de 0,31 y 0,33 respectivamente. El ME indica que los modelos citados tienden a subestimar los valores de  $T_s$  a nivel de subpíxel (valores negativos) con sesgo izquierdo en la distribución de los datos (skewness positivo).

La Figura 5.2 muestra los boxplots de los datos térmicos analizados, donde se observa que la totalidad de los modelos presentan mayor proporción de valores atípicos que los encontrados en la  $T_s$  observada. Lo expresado anteriormente se evidencia de mejor manera en el modelo  $T_s^*$  NDIIharp.

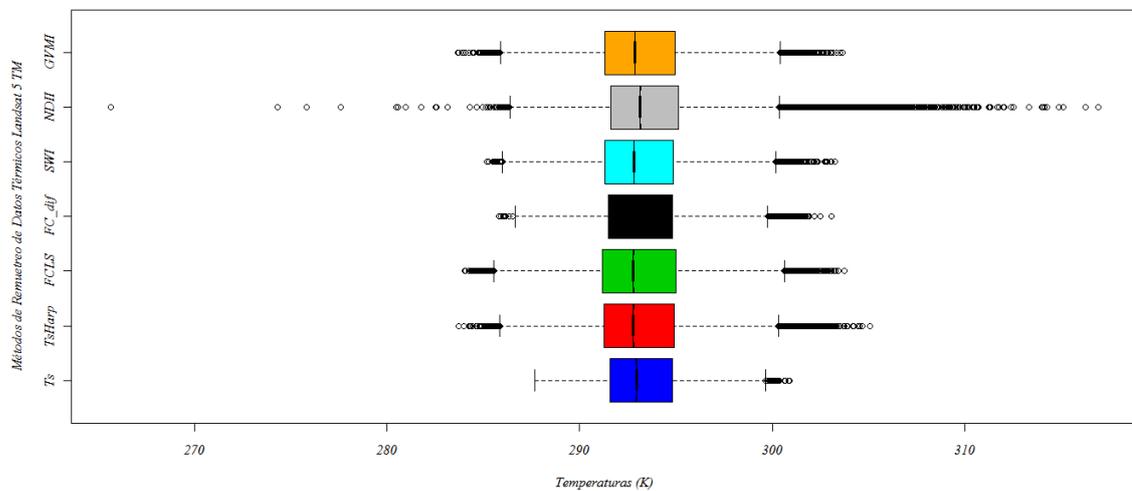
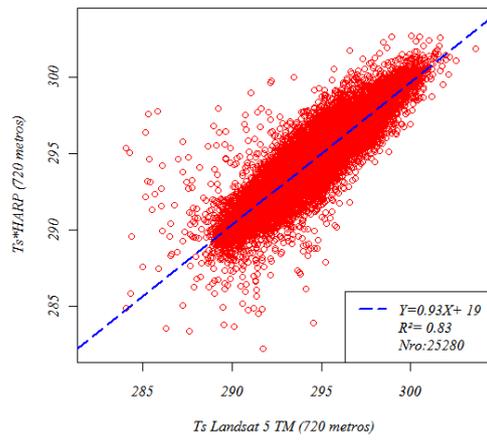
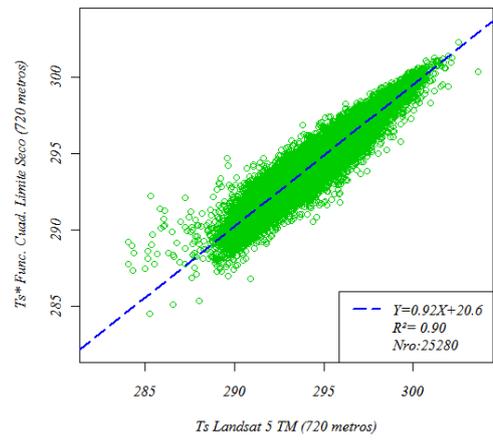


Figura 5.2: Boxplots de los datos térmicos observados ( $T_s$ ) y estimados:  $T_s$ HARP,  $T_s^*$ FCLS,  $T_s^*$  Dif. de límites(FC\_dif),  $T_s^*$ SWIharp,  $T_s^*$ NDIIharp,  $T_s^*$ GVMHarp.

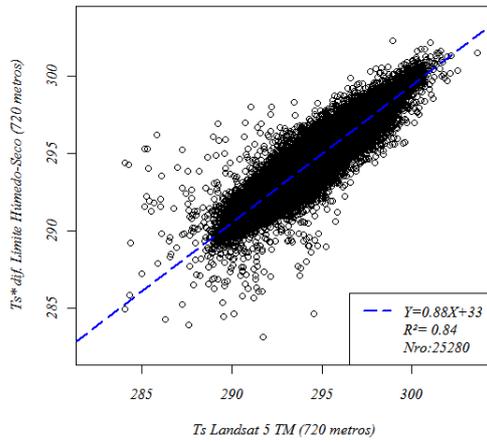
La Figura 5.3 se presenta los modelos de ajuste lineal indicando la correlación de las variables estimada con respecto a la observada para la totalidad de la IS analizada (25.280 píxeles). El  $R^2$  muestra que los modelos  $T_s^*$  FCLS y  $T_s^*$  SWIharp presentan el 90 % de las estimaciones correlacionadas, seguidos por el modelo  $T_s^*$  Dif. de límites y el  $T_s$ HARP, con el 84 y 83 % respectivamente.



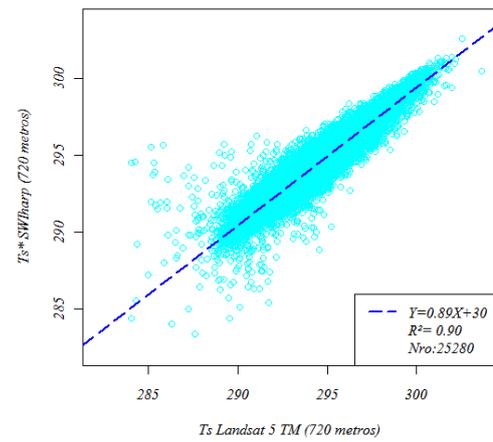
(a)



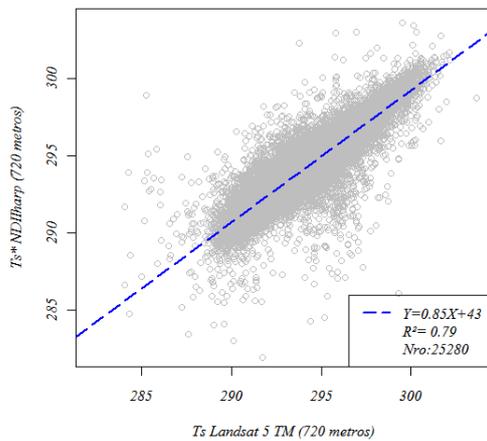
(b)



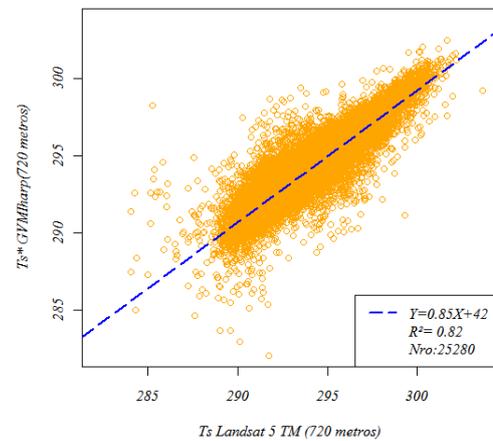
(c)



(d)



(e)



(f)

Figura 5.3: Modelos de ajuste lineal entre la  $T_s$  Landsat 5 TM vs.  $T_s$  estimada por los modelos a 720 m. a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s$ \*FCLS, c)  $T_s$  vs.  $T_s$ \*Dif. Límites, d)  $T_s$  vs.  $T_s$ \*SWIharp, e)  $T_s$  vs.  $T_s$ \*NDIIharp, f)  $T_s$  vs.  $T_s$ \*GVMharp.

Por otra parte, en la Tabla 5.4 se presentan los resultados de los estadísticos extraídos del remuestreo de datos térmicos a resolución espacial de 240 m (227.529 píxeles). Es posible notar que las estimaciones de la  $T_s$  son semejantes a la  $T_s$  observada en términos de media aritmética y mediana. Sin embargo, se muestra una alta variabilidad en la  $T_s$  mínima y máxima, donde su mayor amplitud es presentada por el modelo  $T_s^*$  SWIharp (7,5 K para las  $T_s$  mínimas) y el modelo  $T_s^*$  NDIIharp (13 K para las  $T_s$  máximas). Se observan diferencias de hasta 10 K para los valores de rango estimado y observado (Modelo NDIIharp).

Estadísticos	$T_s$ Landsat 5 TM (240 m)	$T_s$ HARP	$T_s^*$ FCLS	$T_s^*$ Dif. de Límites	$T_s^*$ SWIharp	$T_s^*$ NDIIharp	$T_s^*$ GVMIharp
Mínimo (K)	274,8	278,8	275,6	281,6	282,3	278,3	277,1
1er. Cuartil (K)	292,3	292,2	291,7	292,4	293,1	292,6	292,0
Mediana (K)	294,4	294,3	294,4	294,4	294,9	294,5	294,3
Media (K)	294,3	294,3	294,0	294,3	294,9	294,6	294,2
3er. Cuartil (K)	296,0	296,3	296,3	296,0	296,4	296,4	296,3
Máximo (K)	305,6	304,7	303,6	304,2	303,8	318,7	304,3
Rango (máx-mín) (K)	30,82	25,95	28,02	22,57	21,48	40,47	27,24
Desvío estándar (K)	2,65	2,77	3,18	2,47	2,27	2,67	2,89
Coef. Variación (%)	0,90	0,94	1,08	0,84	0,77	0,90	0,98
Skewness	-0,0263	0,1587	-0,292	0,109	0,104	0,368	-0,032
Curtosis	0,1254	-0,387	-0,297	-0,294	-0,262	0,611	-0,467
RMSE (K)		1,37	1,66	1,08	1,30	1,61	1,40
RE (K)		0,004	0,005	0,003	0,004	0,005	0,004
ME (K)		-0,0039	-0,283	0,0014	0,529	0,278	-0,102
D		0,93	0,90	0,95	0,94	0,90	0,93
RMSE/ $\sigma$		0,49	0,52	0,44	0,57	0,60	0,48

Tabla 5.4: Estadísticos comparativos entre la imagen de  $T_s$  observada Landsat 5 TM y las estimadas a 240 m de resolución espacial.

En la Figura 5.4 se muestra el boxplots de los modelos, donde se puede observar de forma clara que los datos estimados por el modelo  $T_s^*$  Dif. de límites se asemejan a los datos observados, con valores de mediana y rango intercuartilico equivalente.

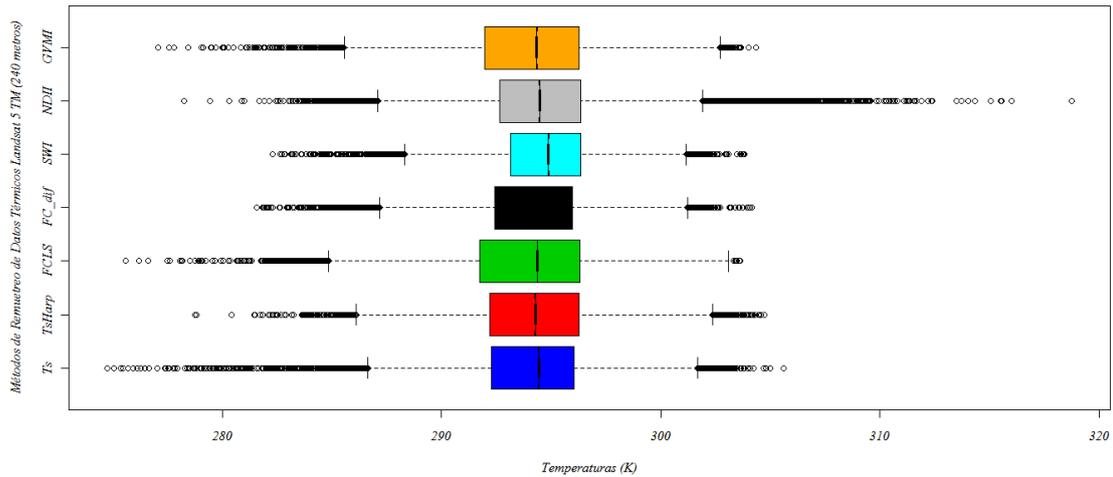
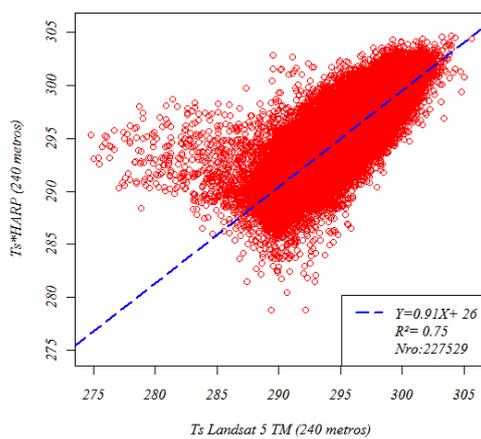
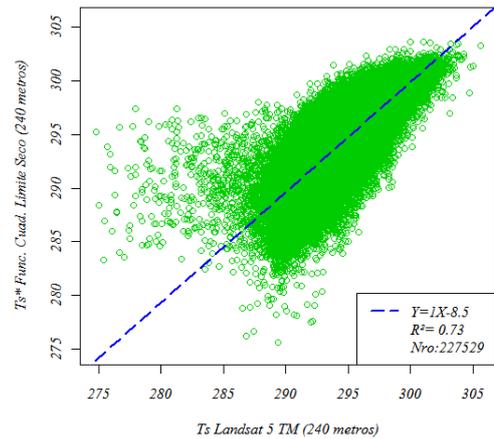


Figura 5.4: Boxplots de los datos térmicos observados ( $T_s$ ) y estimados:  $T_s$ HARP,  $T_s$ \*FCLS,  $T_s$ \* Dif. de límites (FC\_dif),  $T_s$ \*SWIharp,  $T_s$ \*NDIIharp,  $T_s$ \*GVIharp.

Los errores en las estimaciones en término del RMSE presentan un incremento con respecto a los encontrados para los remuestreos a 720 m. La disgregación de la  $T_s$  a nivel de subpíxel produjo un incremento del error de hasta de 1 K para los modelos  $T_s$ \* FCLS y  $T_s$ \* SWIharp. Por otra parte, los estadísticos  $RMSE/\sigma$  y  $d$  muestran que la performance del modelo  $T_s$ \* Dif. de límites presenta la mejor agregación de los datos estimados, con 0,44 y 0,95 respectivamente. De forma coincidente con estos resultados, el modelos  $T_s$ \* Dif. de límites presentar el mejor ajuste, con el 83 % de los datos correlacionados y RMSE más bajo (1 K) (Fig. 5.5).



(a)



(b)

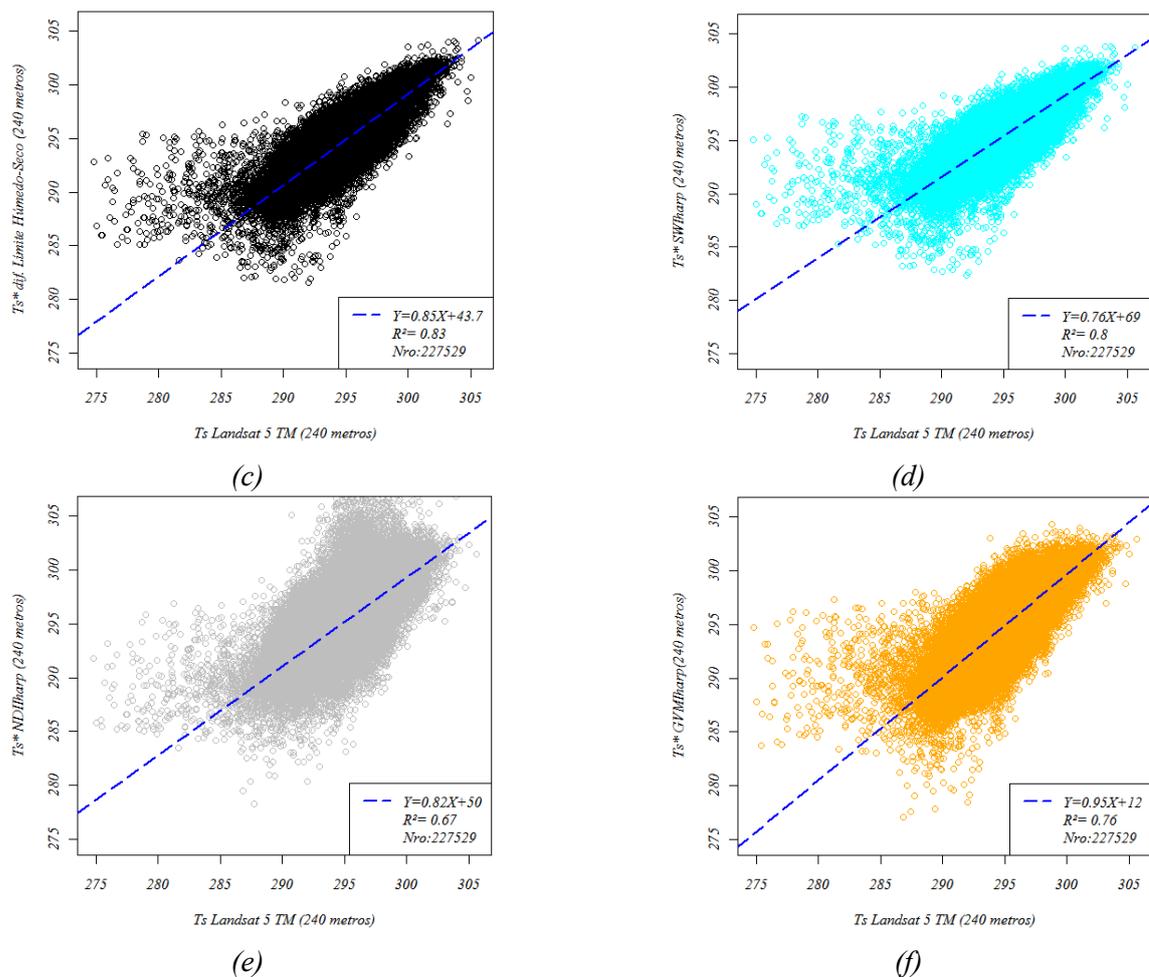


Figura 5.5: Modelos de ajuste lineal entre la  $T_s$  Landsat TM vs.  $T_s$  estimada por los modelos a 240 m, a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s^*$ FCLS, c)  $T_s$  vs.  $T_s^*$ Dif. Límites, d)  $T_s$  vs.  $T_s^*$ SWIharp, e)  $T_s$  vs.  $T_s^*$ NDIIharp, f)  $T_s$  vs.  $T_s^*$ GVMIIharp.

En la Tabla 5.5 es posible notar que la variabilidad en la  $T_s$  observada y estimadas se incrementó significativamente para los datos remuestreados a 120 m de resolución espacial. Además, se indica en el modelo  $T_s^*$  GVMIIharp presenta una variabilidad térmica similar a la  $T_s$  observada, con 56 K. Los modelos cuya metodología está basada en el espacio NDVI -  $T_s$  ( $T_s$  HARP,  $T_s^*$  FCLS y  $T_s^*$  Dif. de límites), presentaron rangos menores a los de la  $T_s$  observada, con valores entre 36,37 y 43,57 K. Sin embargo, la mayor diferencia es indicada por el modelo  $T_s^*$  NDIIharp, con 81,48 K. Por otra parte, se muestra que el rango intercuartílico de los modelos está representado de forma homogénea, lo cual indica que la variabilidad térmica está limitada a los valores extremos.

Estadísticos	$T_s$ Landsat 5 TM (120 m)	$T_s$ HARP	$T_s^*$ FCLS	$T_s^*$ Dif. de Límites	$T_s^*$ SWIharp	$T_s^*$ NDIIharp	$T_s^*$ GVMIIharp
Mínimo (K)	252,2	272,0	272,2	272,1	268,6	248,4	266,5
1er. Cuartil (K)	292,2	292,2	292,1	292,1	292,2	292,5	292,5
Mediana (K)	294,4	294,4	294,4	294,4	294,4	294,6	294,6

<b>Media (K)</b>	294,3	294,3	294,3	294,3	294,3	294,6	294,6
<b>3er. Cuartil (K)</b>	296,2	296,2	296,2	296,2	296,2	296,5	296,5
<b>Máximo (K)</b>	312,7	308,4	306,2	315,7	306,9	329,9	322,6
<b>Rango (máx-mín) (K)</b>	60,58	36,37	34,07	43,57	38,35	81,48	56,12
<b>Desvío estándar (K)</b>	2,76	2,82	2,85	2,84	2,76	2,94	2,87
<b>Coef. Variación (%)</b>	0,94	0,95	0,97	0,96	0,93	0,99	0,97
<b>Skewness</b>	-0,070	0,012	-0,101	-0,042	-0,087	0,045	-0,098
<b>Curtosis</b>	0,319	0,131	0,073	0,130	0,320	1,010	0,554
<b>RMSE (K)</b>		1,16	1,20	1,15	0,98	1,53	1,43
<b>RE (K)</b>		0,0039	0,0040	0,0039	0,0033	0,0052	0,0048
<b>ME (K)</b>		-0,0038	-0,06942	0,0009	0,0135	0,2320	0,2318
<b>D</b>		0,95	0,95	0,95	0,97	0,92	0,93
<b>RMSE/<math>\sigma</math></b>		0,41	0,42	0,40	0,35	0,52	0,49

Tabla 5.5: Estadísticos comparativos entre la imagen de  $T_s$  observada Landsat 5 TM y las estimadas a 120 m de resolución espacial.

Los errores estadísticos evaluados en términos del RMSE y RE son similares a los obtenidos por los modelos de remuestros a 240 m de resolución espacial, indicados con valores inferiores a 1,5 y 0,0052 K respectivamente. El modelo  $T_s^*$  SWIharp presenta el menor error estadístico, con 0,98 y 0,0033 K; indicando la mejor eficiencia en la agregación de los datos térmicos, con  $RMSE/\sigma$  de 0,35 y  $d$  de 0,97. Por otra parte, los valores BIAS cercanos a 0 evidencian que el modelo  $T_s^*$  Dif. de límites y el  $T_s^*$  SWIharp no tienen tendencia a la sobrestimación o subestimación de los datos térmicos (Tabla 5.5). La Figura 5.6 muestra los boxplots los datos de  $T_s$  estimados con respecto a los observados. Si bien los boxplots indican una alta homogeneidad en los estadísticos representados, es posible notar que los modelos basados en índices de estrés hídrico producen mayor cantidad de valores atípicos que los basados en contexto NDVI -  $T_s$ .

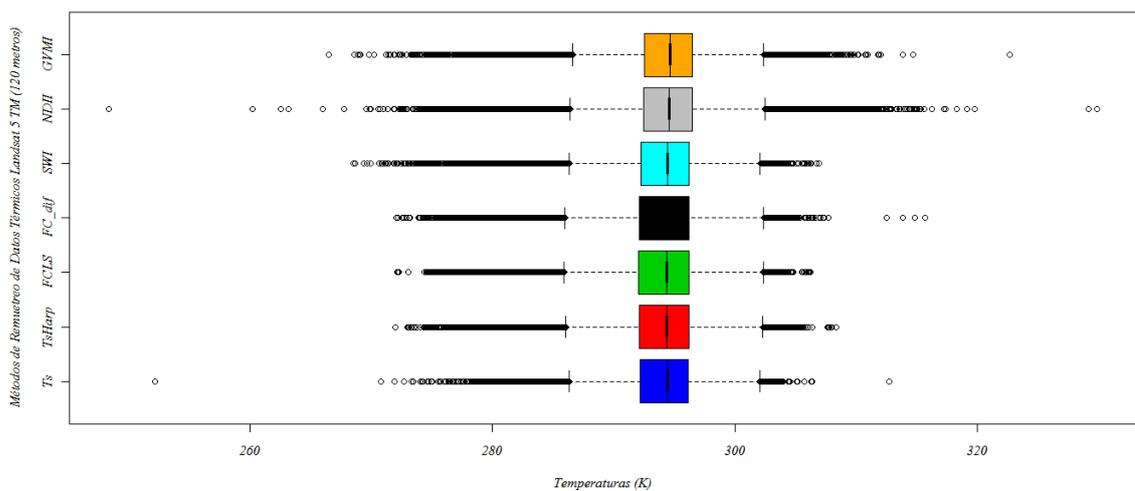


Figura 5.6: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados:  $T_s$ HARP,  $T_s^*$ FCLS,  $T_s^*$  Dif. de límites ( $FC\_dif$ ),  $T_s^*$ SWIharp,  $T_s^*$ NDIIharp,  $T_s^*$ GVMharp.

En la Figura 5.7 se presentan los modelos de ajuste para los modelos de remuestreo a 120 m, donde se observa que modelo  $T_s^*$  SWIharp posee el 88 % de los 914.890 píxeles evaluados se encuentran correlacionados. El modelo  $T_s$ HARP, el  $T_s^*$  FCLS y el  $T_s^*$  Dif. de límites también presentan altos valores de  $R^2$ , con 0,83 - 0,82 y 0,84 respectivamente.

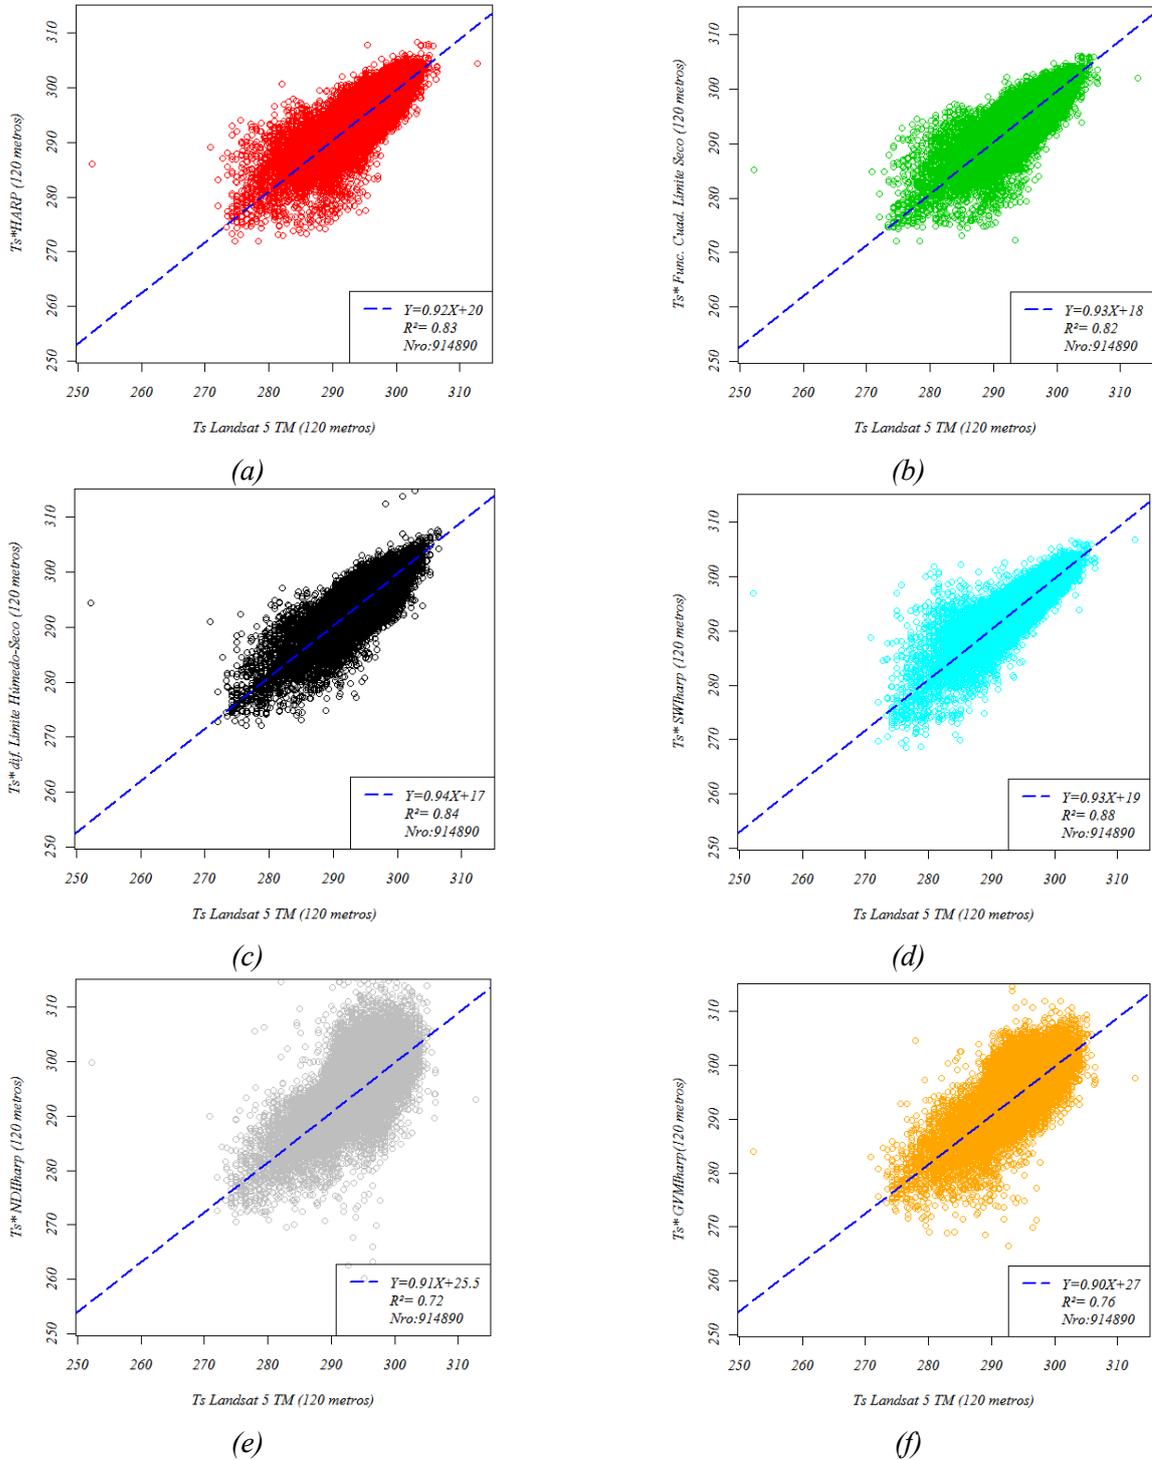


Figura 5.7: Modelos de ajuste lineal entre la  $T_s$  Landsat TM vs.  $T_s$  estimada por modelos a 120 m. a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s^*$ FCLS, c)  $T_s$  vs.  $T_s^*$  Dif. Límites, d)  $T_s$  vs.  $T_s^*$ SWIharp, e)  $T_s$  vs.  $T_s^*$ NDIharp, f)  $T_s$  vs.  $T_s^*$ GVMharp.

En la Figura 5.8 se presentan en un mismo gráfico los resultados que sirvieron para evaluar la performance de los modelos a diferentes resoluciones. Al incluir en un mismo gráfico la información resultante es posible identificar patrones en la tendencia general en la performance de los modelos. El  $R^2$  de los sucesivos remuestreos muestra que existe una tendencia decreciente de los valores a medida que disminuye el tamaño de píxel con una leve inflexión para 240 m (Fig. 5.8 a). Esa tendencia se indica en mayor medida cuando existen saltos significativos en la resolución espacial (por ejemplo: de 720 a 240 m). Sin embargo, el estadístico  $R^2$  tiene tendencia a mantenerse invariante para el modelo  $T_s^*$  Dif. de límites (líneas punteada negra) a través de los remuestreos. Por lo contrario, el  $T_s^*$  SWIharp mostró los mejores resultados en términos del estadístico  $R^2$  sin permanecer invariable (Fig. 5.8 a).

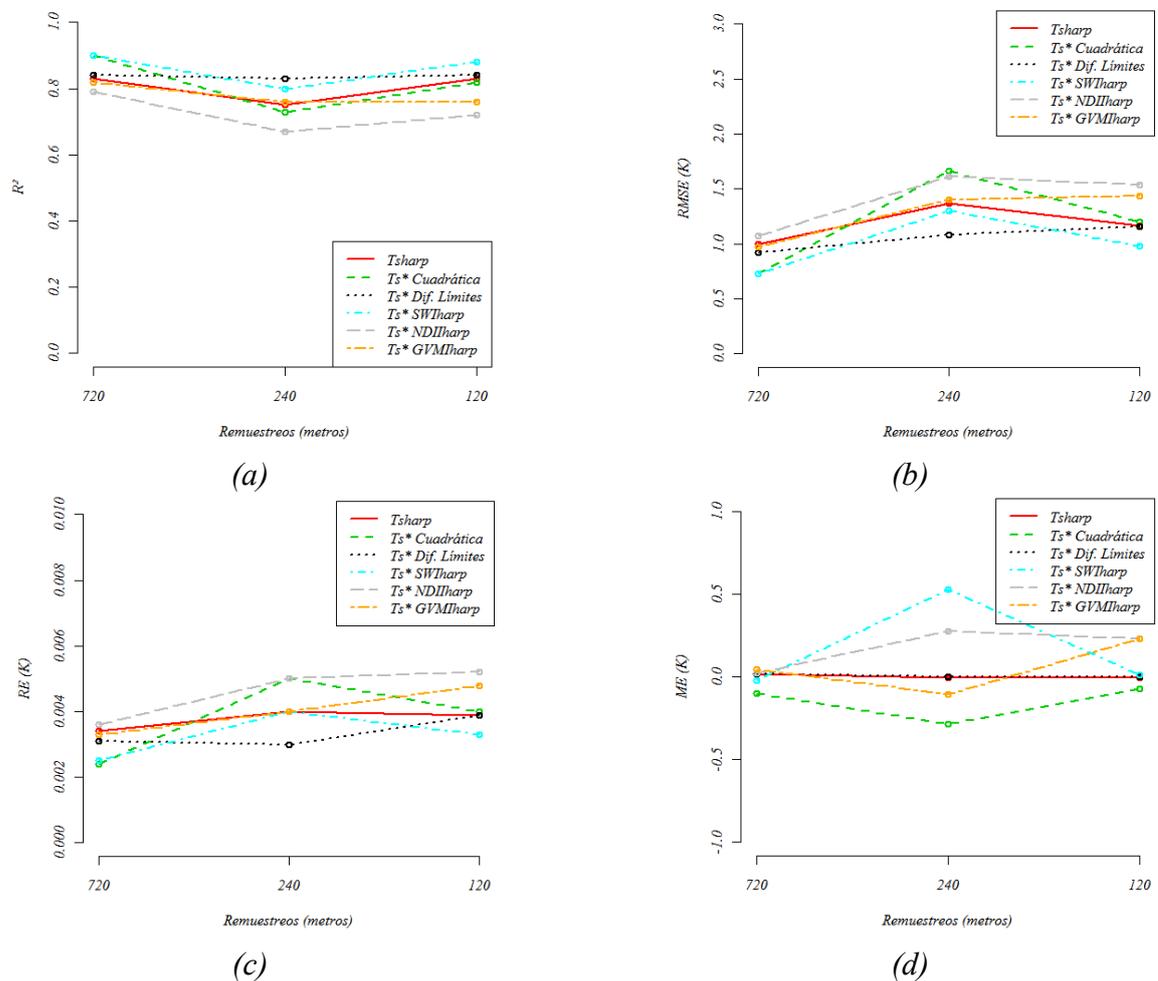


Figura 5.8: Resultados de estadísticos a diferentes resoluciones espaciales de la imagen Landsat TM. a)  $R^2$ , b) RMSE (K), c) RE (K) d) ME (K).

La Figura 5.8. b y c del RMSE y RE presentan patrones en los errores estadísticos para las diferentes agregaciones. Los modelos de remuestreo tienden al incremento del error en los pasos de

remuestreo. Particularmente, los mayores valores de RMSE y RE se observan entre los 720 m a 240 m de resolución espacial.

La Figura 5.8. d indica que el modelos  $T_s$ HARP y el  $T_s^*$  Dif. de límites no muestran tendencia a la sobrestimación o subestimación de los datos térmicos, presentando valores cercanos a 0 K. Por el contrario, los modelos restantes indican altos BIAS, donde se producen saltos de escala significativos.

Con propósito de evaluar la precisión de los modelos a mayor resolución espacial, fue agregada la imagen de  $T_s$  (120 m) a 30 m aplicando las técnicas de remuestreo. De las imágenes generadas se extrajo una muestra aleatoria del 4 % de los píxeles considerados en la imagen (57.481 píxeles) utilizando la técnica geostadística de semivariograma con el propósito de seleccionar una cantidad de píxeles estadísticamente representativos (*Ver apartado 4.2*). En la Figura 5.9 se presentan los semivariogramas en dirección E - O (a) y N - S (b) para la imagen de  $T_s$  de 30 m, generados a partir de la herramienta Global Spatial Statistics del software ENVI 4.7. Considerando un rango espacial de 100 píxeles, la independencia espacial de la variable se encontró a los 40 y 60 píxeles respectivamente. Por lo tanto, fue considerado un umbral de distancia promedio de 50 píxeles (1500 m) para seleccionar la muestra.

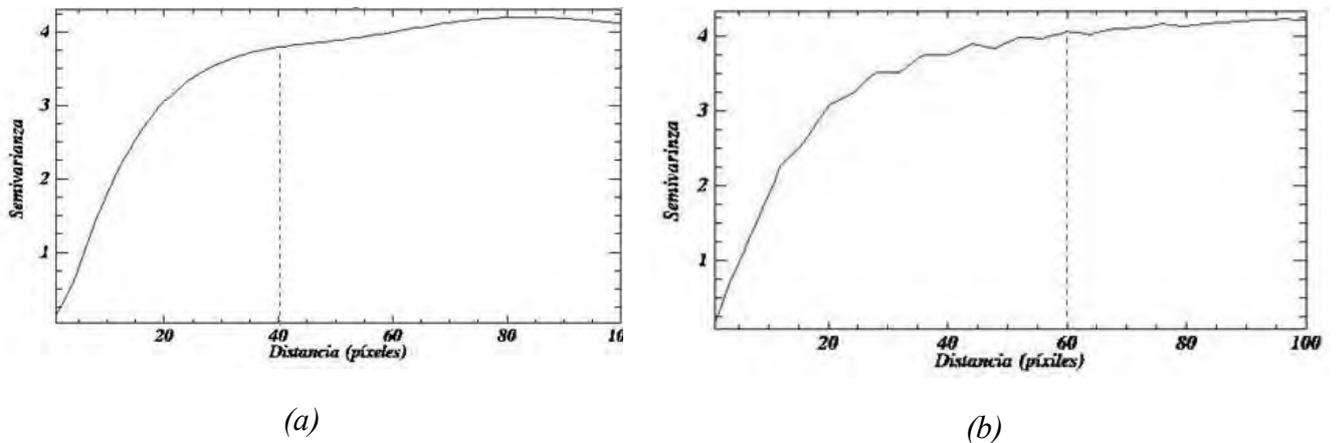


Figura 5.9: Semivariograma de imagen  $T_s$  Landsat TM (30m). a) Sentido Este - Oeste, b) Sentido Norte - Sur.

En la Tabla 5.6 se presentan los descriptores estadísticos para los modelos de remuestreo a 30 m de resolución espacial. Los datos estimados en término de los descriptores estadísticos de rango y media aritmética muestran una variabilidad térmica similar con respecto a los datos de  $T_s$  observados. Sin embargo, la mayor diferencia es encontrada en el modelo  $T_s^*$  NDIIharp, con 37,3 K.

Estadísticos	Ts Landsat 5 TM (30 m)	TsHARP	Ts*FCLS	Ts* Dif. de Límites	Ts* SWIharp	Ts* NDIIharp	Ts* GVMharp
Mínimo (K)	274,9	276,4	275,7	275,3	275,6	273,8	275,9
1er. Cuartil (K)	292,2	292,1	292,0	292,2	292,1	292,4	292,1
Mediana (K)	294,5	294,4	294,4	294,4	294,4	294,6	294,4
Media (K)	294,3	294,3	294,3	294,3	294,3	294,5	294,3
3er. Cuartil (K)	296,2	296,3	296,3	296,2	296,2	296,4	296,3
Máximo (K)	306,4	306,3	305,8	306,4	305,8	311,1	306,0
Rango (máx-mín) (K)	31,42	29,96	30,06	30,15	30,17	37,33	30,12
Desvío estándar (K)	2,75	2,90	2,91	2,79	2,83	2,88	2,86
Coef. Variación (%)	0,935	0,988	0,991	0,950	0,963	0,978	0,972
Skewness	0,076	0,024	0,073	-0,066	-0,0535	0,026	0,033
Curtosis	0,248	0,049	0,069	0,220	0,095	0,442	0,0287
RMSE (K)		1,01	1,02	0,58	0,76	1,06	0,90
RE (K)		0,0034	0,0034	0,0019	0,0025	0,0036	0,0030
ME (K)		0,0034	0,064	-0,0018	-0,0486	0,1908	0,0048
d		0,96	0,96	0,98	0,98	0,96	0,97
RMSE/ $\sigma$		0,34	0,35	0,20	0,26	0,36	0,31

Tabla 5.6: Estadísticos comparativos entre la imagen de  $T_s$  observada Landsat 5 TM y las estimadas a 30 m de resolución espacial.

En la Figura 5.10 se muestra el gráfico Q - Q plot donde se indica la distribución de la  $T_s$  observada en referencia a una línea normal teórica. Se muestra una alta correlación entre los datos con respecto a la línea normal desde la media aritmética hasta los valores de  $T_s$  más altos. Sin embargo, los valores de  $T_s$  más bajos se muestran separados de la línea normal, indicando píxeles con alta variabilidad térmica introducida por las diferentes combinaciones entre la proporción de suelo y vegetación (*Ver histogramas de frecuencia en el Anexo VI*).

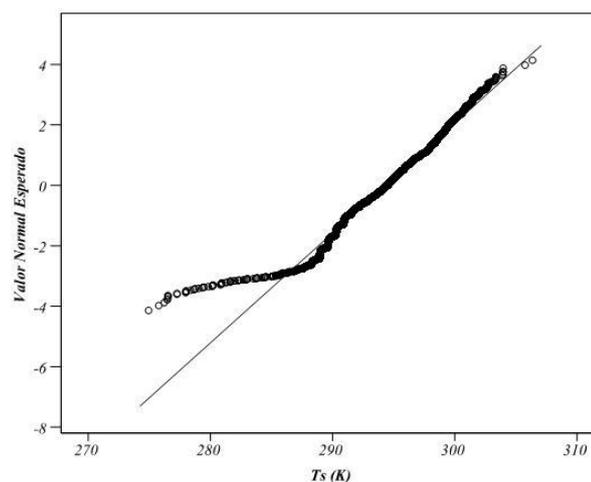


Figura 5.10: Q - Q plot de la  $T_s$  observada con respecto al valor normal esperado.

En la Figura 5.11 se muestran los boxplots para la  $T_s$  observada y estimadas, donde es posible notar la una alta similitud. Se puede notar que el modelo  $T_s^*$  Dif. de límites y el  $T_s^*$  SWIharp indican la mayor semejanza en relación a la  $T_s$  medida.

Un alto nivel de agregación es indicado en el modelo  $T_s^*$  Dif. de límites y el  $T_s^*$  SWIharp, con un valores menores a 0,98 para el coeficiente de Willmott y 0,26 para el estadístico  $RMSE/\sigma$ . Los estadísticos RMSE y RE para los mismos modelos se referencian como los más bajos, con 0,58 - 0,76 y 0,0019 - 0,0025 respectivamente (Ver Tabla 5.6).

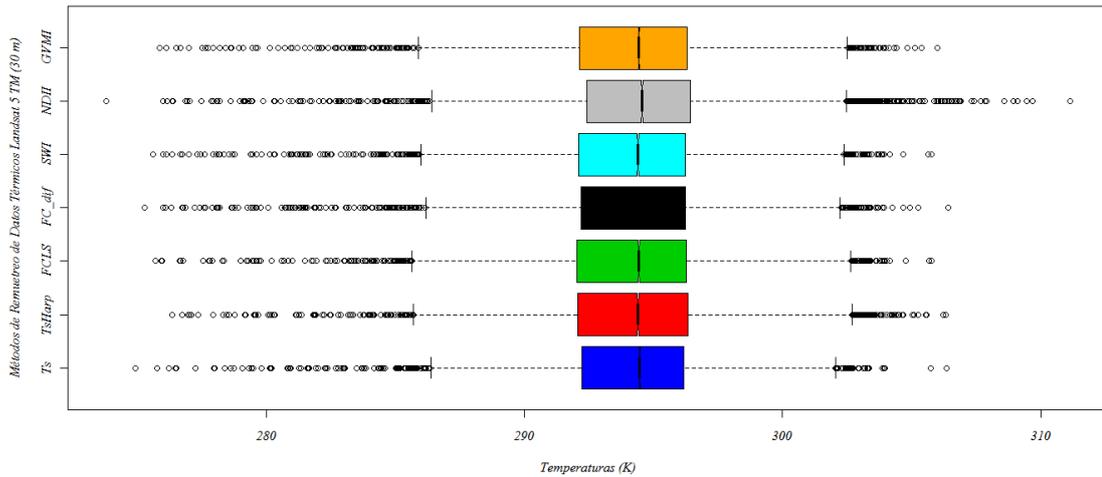
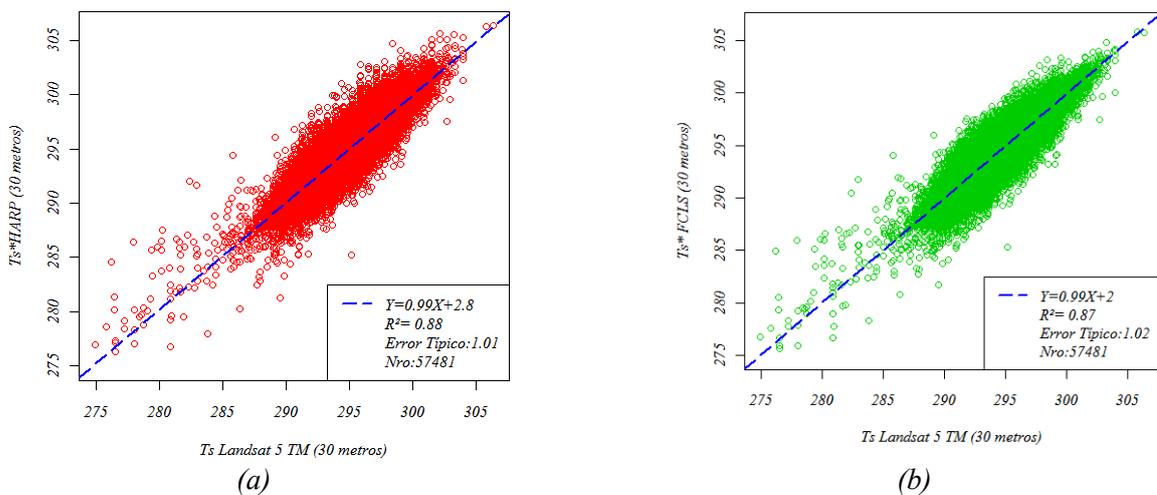


Figura 5.11: Boxplot de los datos térmicos obserbados ( $T_s$ ) y estimados a 30 m de resolución espacial:  $T_s$ HARP,  $T_s^*$ FCLS,  $T_s^*$  Dif. de límites (FC\_dif),  $T_s^*$ SWIharp,  $T_s^*$ NDIIharp,  $T_s^*$ GVMiharp.

La Figura 5.12 muestra los modelos de ajuste lineal, donde se observa una correlación superior al 86 % para la totalidad de los modelos. Puntualmente, modelo  $T_s^*$  Dif. de límites y el  $T_s^*$  SWIharp presentan la mejor correlación en término de  $R^2$ , con 0,95 y 0,91 respectivamente.



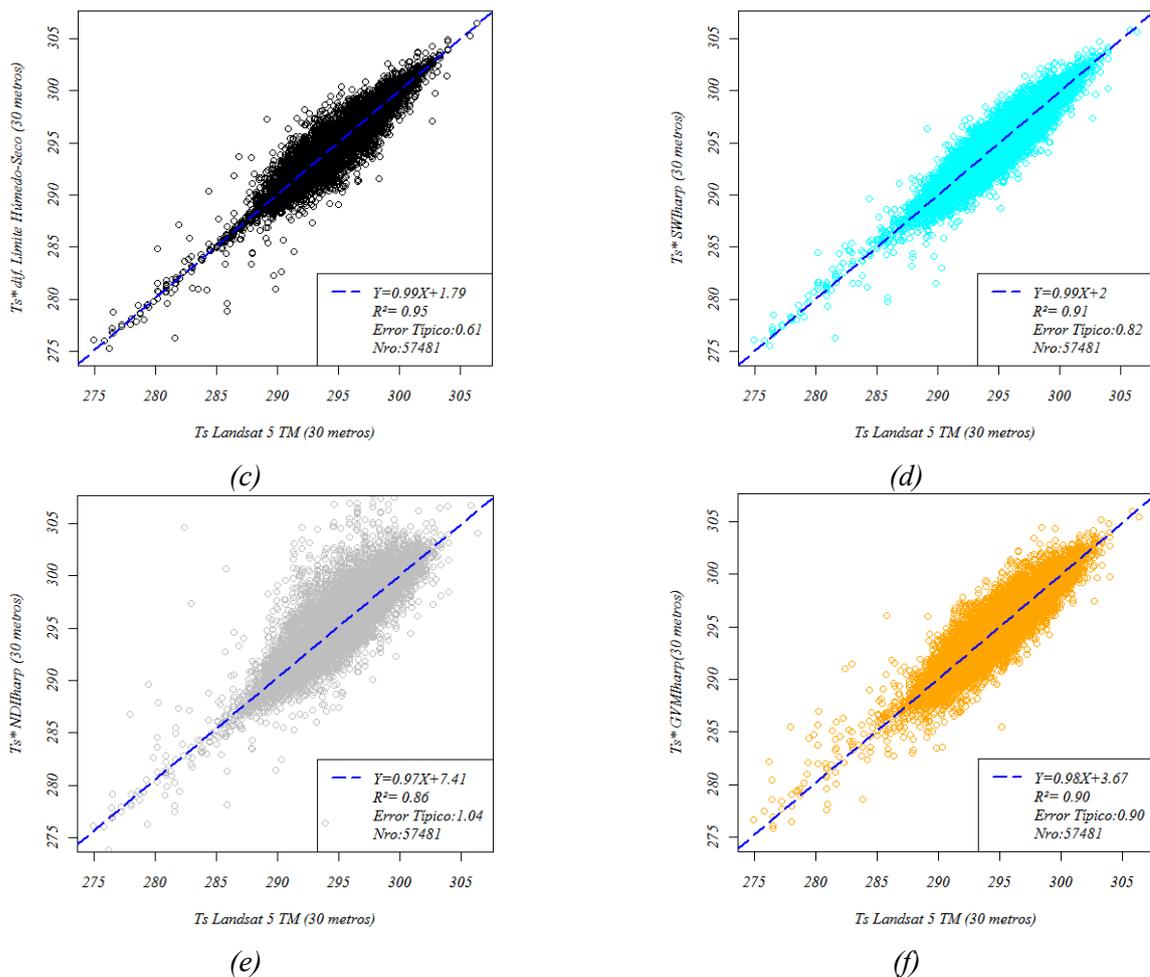


Figura 5.12: Modelos de ajuste lineal entre la  $T_s$  Landsat TM vs.  $T_s$  estimada por modelos a 30 m. a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s$ \*FCLS, c)  $T_s$  vs.  $T_s$ \*Dif. Límites, d)  $T_s$  vs.  $T_s$ \*SWIharp, e)  $T_s$  vs.  $T_s$ \*NDIharp, f)  $T_s$  vs.  $T_s$ \*GVMiharp.

### 5.3. ANÁLISIS DE MODELOS POR TIPO DE COBERTURA

Fueron evaluados los modelos de remuestreo en términos de análisis global de las IS, considerando de forma integrada la totalidad de los usos de suelo o coberturas contenidas en la escena. Sin embargo, es interesante analizar la respuesta de los diferentes modelos para cada cobertura en particular. Por lo tanto, se analizaron modelos para diferentes clases contenidas en la imagen Landsat TM para el 23/02/2010, las mismas se identificaron en un mapa de uso de suelo realizado a partir de una clasificación de la IS.

La clasificación de la IS se realizó aplicando el algoritmo no supervisado ISODATA utilizando las bandas 3, 4, 5 y 7 del sensor TM. Para los sectores de bajo, media loma y loma presentes en la escena se identificaron cinco clases de interés (soja de primera y segunda, girasol, maíz y suelo desnudo) con 98 % de precisión (coeficiente Kapa 0,97) a partir de 50 clases agrupadas (Fig. 5.13).

Las clases identificadas sirvieron para seleccionar muestras de 1000 píxeles en la  $T_s$  observada y estimada. Posteriormente, se analizó la performance de los modelos de remuestreos en términos de ajuste lineal y descriptores estadísticos citados en las secciones previas.

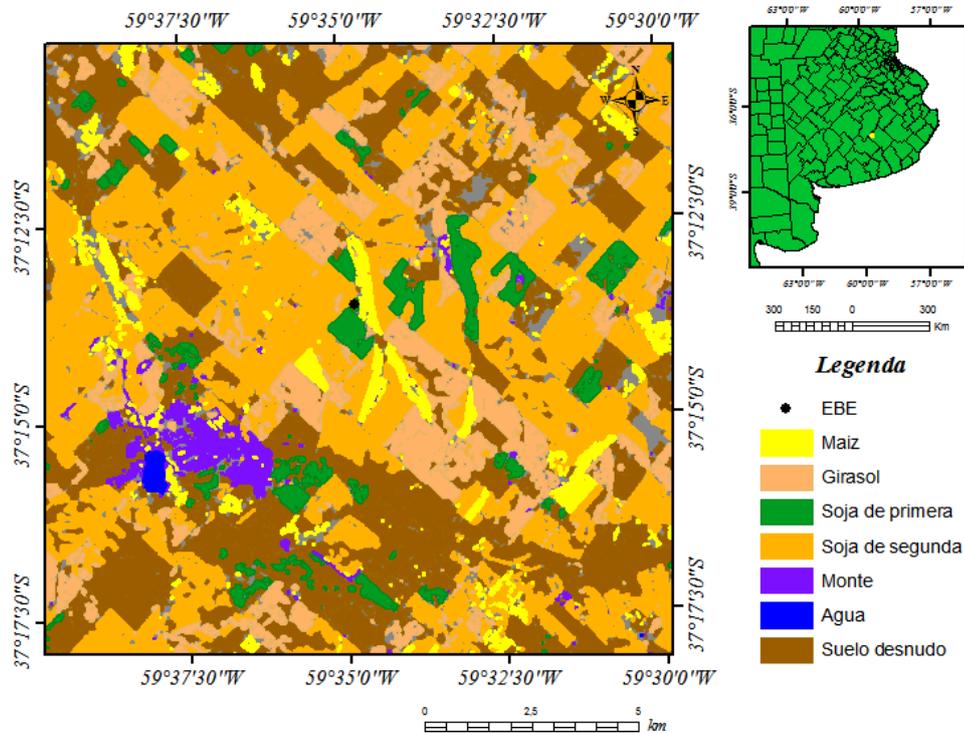


Figura 5.13: Clasificación ISODATA para la imagen Landsat TM del 23/02/2010.

La Figura 5.14 a y b muestra la performance de los modelos de remuestreo para los diferentes tipos de coberturas de suelo en términos de los estadísticos  $R^2$  y error residual estándar de los modelos de ajuste. Los valores de  $R^2$ , graficados en la Figura 5.14 a, indican que el modelo  $T_s^*$  Dif. de límites (línea punteada negra) presenta entre el 76 y 90 % de los valores correlacionados. El modelo  $T_s^*$  SWIharp (línea punto raya celeste) presentó resultados similares, con valores de  $R^2$  entre 0,66 y 0,85.

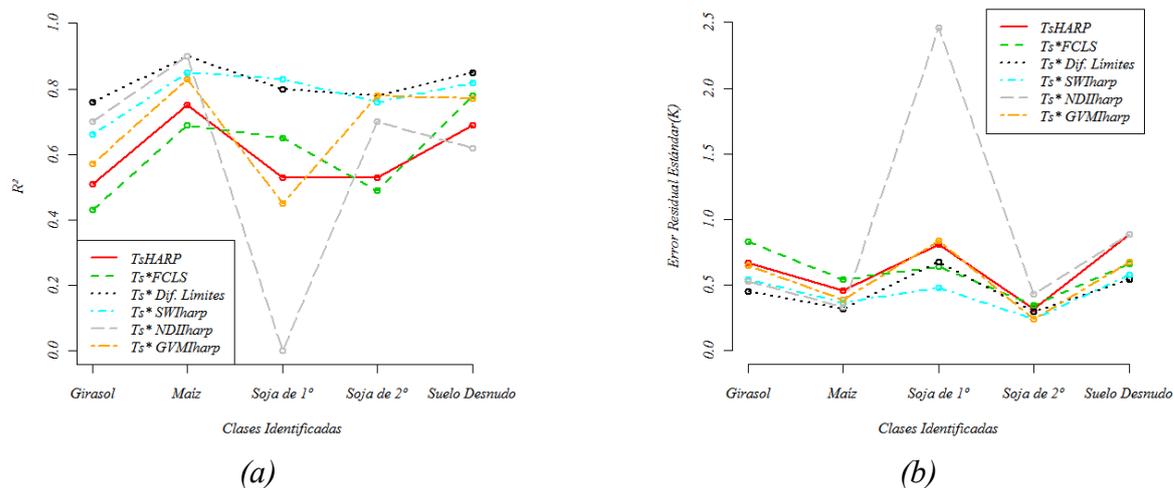


Figura 5.14: a)  $R^2$ , b) Error Residual Estándar de modelos de remuestreo por clases.

Las coberturas identificadas como soja de primera y de segunda para los diferentes modelos muestran tendencia al decrecimiento de la precisión mostrando los peores ajustes. Para la clase soja de primera evaluada en término del modelo  $T_s$ \* NDIharp, se indica que los datos no se muestran correlacionados, presentando un error residual de 2,5 K. Particularmente, los modelos basados en índices de estrés hídrico presentaron los peores ajustes para la clase soja de primera. La representación de la  $T_s$  resulta de mayor complejidad para cubiertas vegetales con contenido de humedad variable, indicando que el modelo  $T_s$ \* NDIharp y el  $T_s$ \* GVMharp muestran déficit al respecto (Fig. 5.14 a b).

Los errores estadísticos representados por el RMSE y RE indican que la clase soja de primera mostró tendencia creciente para la totalidad de los modelos. Particularmente, el modelo  $T_s$ HARP (línea llena roja), el  $T_s$ \* NDIharp (línea punteada gris) y el  $T_s$ \* GVMharp (línea punteada naranja) presentaron mayores errores en relación a los estadísticos RMSE (1,18 - 3 y 1,22 K) y RE (0,004 - 0,01 y 0,0041 K). Estos errores indicados para la clase soja de primera podrían estar estrechamente relacionados con las condiciones de la vegetación. Para el periodo en estudio la soja de primera se encontraba en la etapa próxima a la senescencia y por lo tanto, existe una mezcla de vegetación en diferentes condiciones (plantas verde con buena humedad y secas con fruto o semilla). Estas condiciones podrían explicar la variación observada por los modelos. Por otra parte, el modelo  $T_s$ \* Dif. de límites (línea punteada negra) obtuvo los mejores resultados de los estadísticos RMSE y RE, con 0,69 y 0,0023 K respectivamente (Figura 5.15 a b).

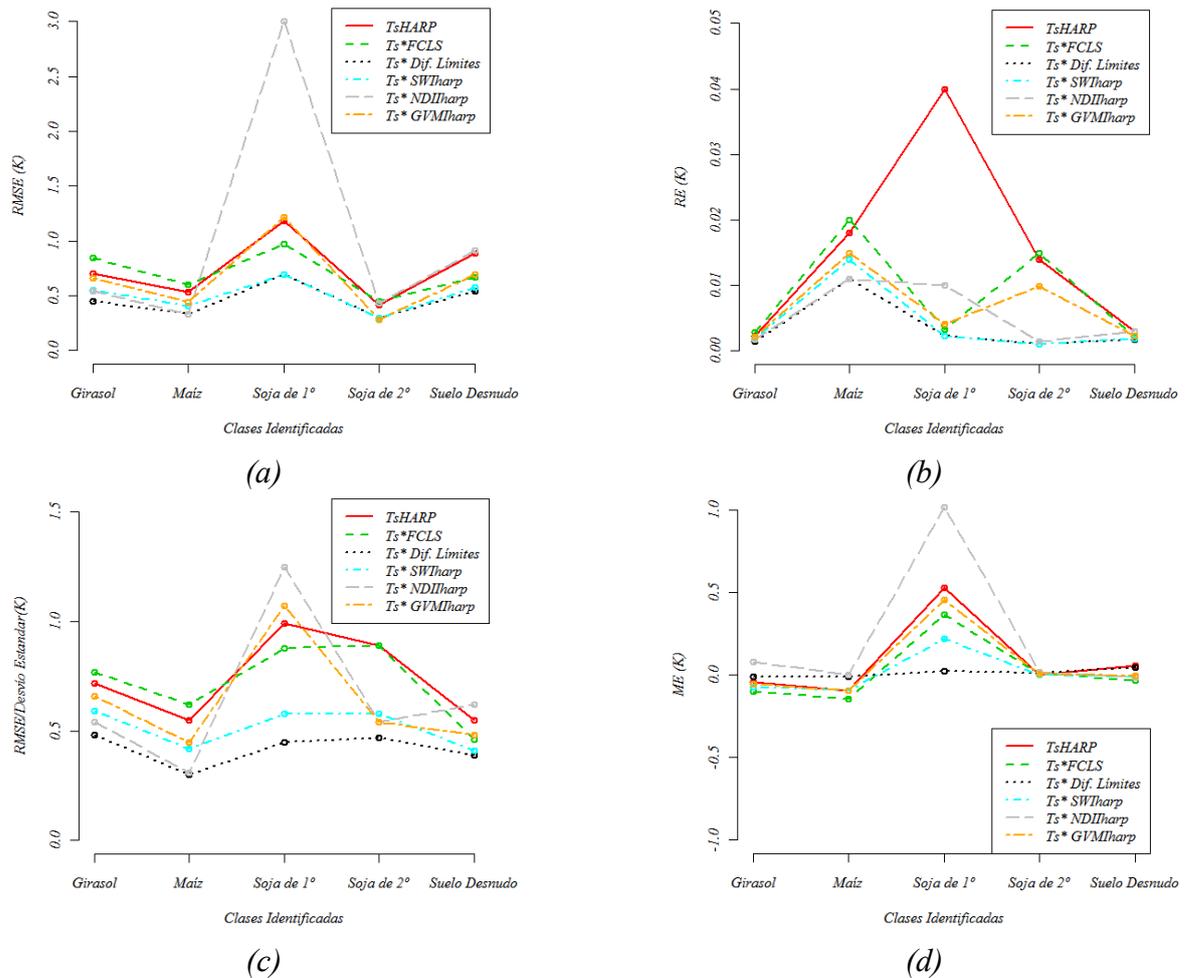


Figura 5.15: a) RMSE, c) RE, d) RMSE/ $\sigma$ , e) ME de modelos de remuestreo en función de las clases identificadas en la imagen Landsat TM del 23/02/2010 a 30 m de resolución espacial.

La mayor agregación de los datos representada por el estadístico RMSE/ $\sigma$  es indicada en la clase maíz y suelo desnudo. Particularmente, el modelo  $T_s$ \* Dif. de límites (línea punteada negra) presenta los mejores resultados con respecto al estadístico RMSE/ $\sigma$ , con 0,3 y 0,39 para las clases maíz y suelo desnudo respectivamente (Fig. 5.15 c). Por otro lado, el estadístico ME muestra que el método  $T_s$ \* Dif. de límites se muestra invariante para las diferentes clases analizadas, presentando valores de ME cercanos a 0 K (Fig. 5.15 d).

## Capítulo VI - RESULTADOS OBTENIDOS A PARTIR DE IMÁGENES MODIS

### 6.1. EVALUACIÓN GLOBAL DE LOS MODELOS

El objetivo de esta sección es evaluar y analizar la eficiencia del método de remuestreo de datos térmico a nivel de subpíxel utilizando la imagen MODIS Terra adquirida el 23/02/2010. En este sentido, se propone evaluar la performance en base a los métodos descritos en el capítulo IV. Para la obtención de las imágenes de  $T_s$  (Ver mapa en Anexo VII) se aplicó la ecuación Split Window (ecuación 4.36) y con estos datos se siguió el esquema metodológico presentado en la Figura 4.3 (Capítulo 4), se identificaron las funciones de los límites en el espacio NDVI -  $T_s$  para la resolución de 4 km. La Figura 6.1 muestra las funciones de regresión utilizadas para realizar la agregación de la  $T_s$  a nivel de subpíxel.

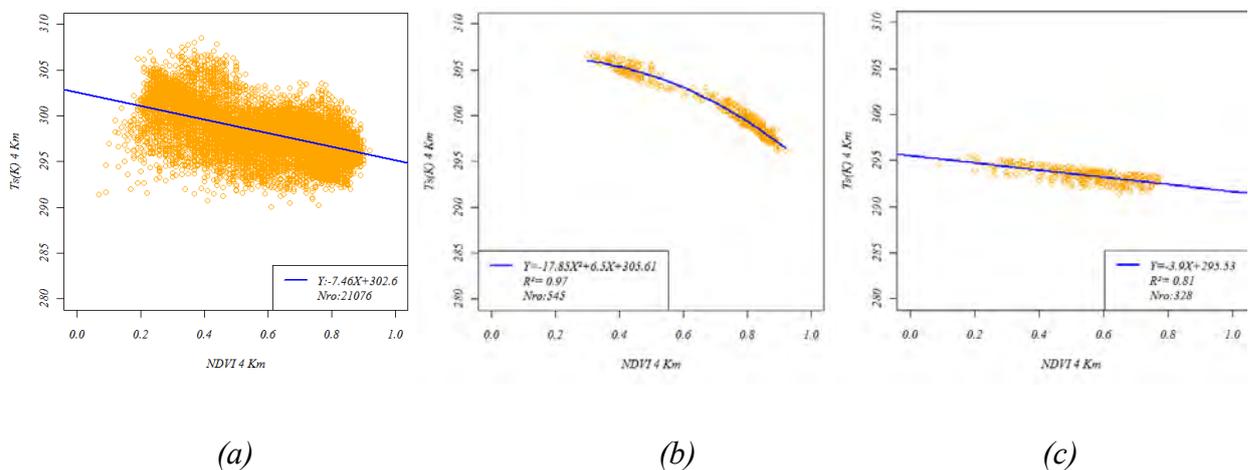


Figura 6.1: Funciones utilizadas en el método para remuestrear datos térmicos a partir de la imagen de  $T_s$  MODIS-Terra remuestreada a 4 km. a) Modelo de ajuste lineal del espacio NDVI- $T_s$ , b) Ajuste cuadrático (límite seco), c) Ajuste lineal (límite húmedo).

A partir de estas funciones, se realizó un primer análisis global de los métodos considerando 80 % de la provincia de Buenos Aires, donde se seleccionó un área de la región pampeana de aproximadamente 286.505 km<sup>2</sup>. Se evaluó el comportamiento de las técnicas de remuestreo por medio de un análisis estadístico comparativo entre la temperatura observada y estimada. En una segunda aproximación a escala regional se analizaron dos tipos de cubiertas diferentes dentro de ambientes bien definidos de la región pampeana. El primer análisis se realizó sobre un área de 10.120 Km<sup>2</sup> ubicada en el centro de la provincia de Buenos Aires (partido de Tandil, Azul y Olavarría), caracterizada por suelos con alta cobertura vegetal para la época del año analizada. El segundo análisis considera suelos desnudos o con baja proporción de vegetación de la parte suroeste

de la provincia de La Pampa (partidos de Lihuel Calel, Huacal y Caleu Caleu), abarcando un área de 4.874 Km<sup>2</sup>.

La Figura 6.2 muestra la distribución de los datos estimados y observados por medio de histogramas de frecuencias. De acuerdo a los resultados obtenidos, los histogramas muestran gran similitud en la distribución de la frecuencias y su localización nos permite caracterizar la temperatura de superficie según el modelo planteado en clases que presentan un sesgo positivo. El ancho de los intervalos de temperatura estimados por los métodos en relación al medido muestra un adecuado comportamiento con mejores resultados en el modelo  $T_s^*$  Dif. de límites y el  $T_s^*$  GVMlharp (Fig. 6.2 d - h).

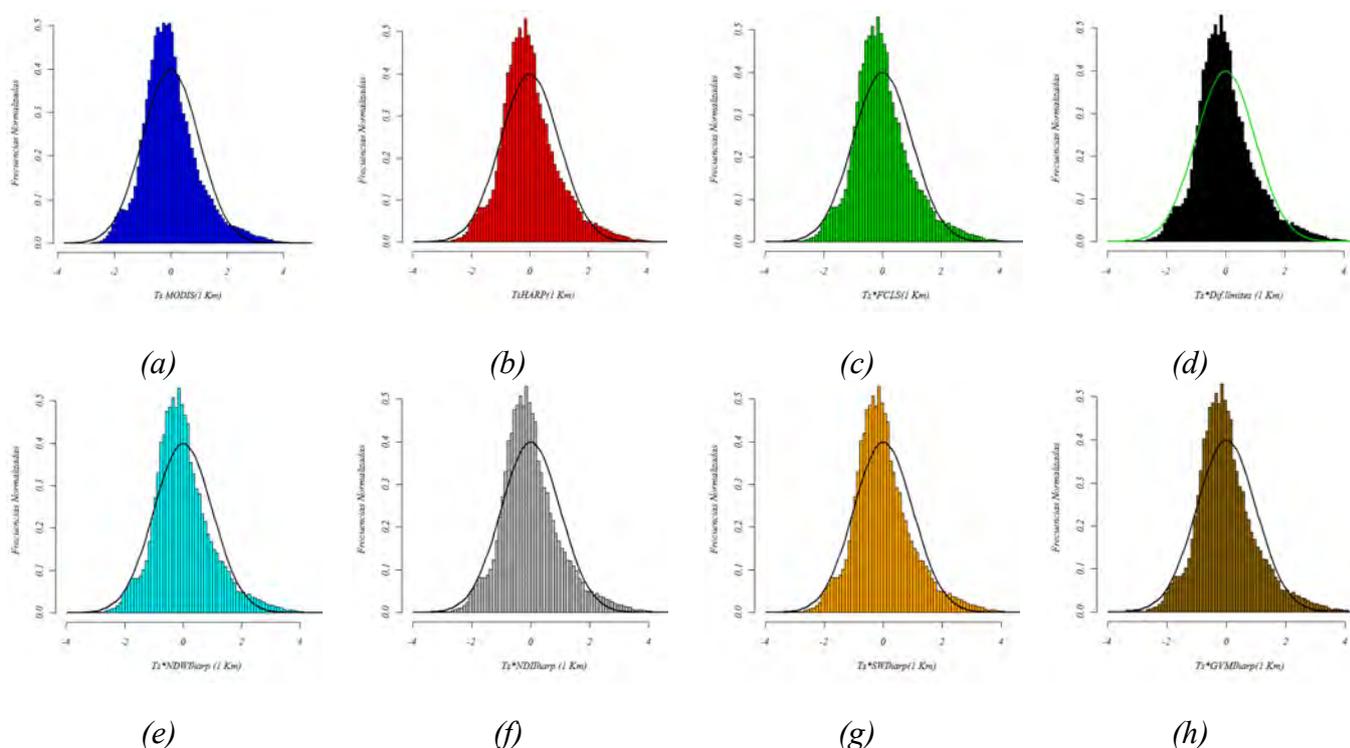


Figura 6.2: Histogramas de frecuencias para los datos observados y estimados para los diferentes métodos. a)  $T_s$  observada , b)  $T_s$ HARP, c)  $T_s^*$ FCLS, d)  $T_s^*$ Dif. Límites, e)  $T_s^*$  NDWIharp, f)  $T_s^*$ NDIIharp, g)  $T_s^*$ SWIharp h)  $T_s^*$ GVMlharp.)

La asimetría en la distribución de los datos térmicos se determinó en base la skewness, donde los valores positivos indican que la distribución tiene tendencia hacia la izquierda de la media. La estimación que más se acerca a una distribución simétrica (skewness = 0) es el modelo  $T_s^*$  FCLS (Ver Tabla 6.1). Por otra parte, los valores positivos mayores a 1 de la curtosis muestran una centralización de los datos en torno a la media, característica de una distribución leptocúrtica. La Figura 6.2 también muestra de forma gráfica una función gaussiana que representa de forma teórica

la normalidad de la muestra. Con el propósito de comprobar la normalidad de los datos observados y estimados fueron aplicados los test de normalidad de Kolmogorov-Smirnov y Chi-cuadrado, tomando en consideración un intervalo de confianza de 95 % se aplicaron los test sobre un tamaño de muestra de 286.505 píxeles en el software estadístico R. De acuerdo al resultado obtenido para los diferentes test (p-valor de  $2,22 \cdot 10^{-16}$ ), se considera que no existe suficiente evidencia estadística para aceptar la hipótesis de normalidad para el tamaño de muestra analizado.

La estadística descriptiva ofrece una primera valoración sobre el comportamiento de cada modelo y su grado de homogeneidad. En la Tabla 6.1 se presentan los resultados estadísticos de los métodos aplicados a la imagen de  $T_s$  MODIS. En esta se presentan los descriptores estadísticos: mínimo, máximo, rango, mediana, media aritmética, rango intercuartílico, desvío típico y coeficiente de variación, skewness y la curtosis de los datos analizados. Además se incluyen en la Tabla 6.1 los estadísticos para la estimación de los errores (RMSE, ME,  $RMSE/\sigma$  y el índice de concordancia de *Willmott*).

Estadísticos	$T_s$ MODIS (1 Km)	$T_s$ HARP	$T_s^*$ FCLS	$T_s^*$ Dif. de Límites	$T_s^*$ NDWIharp	$T_s^*$ NDIIharp	$T_s^*$ SWIharp	$T_s^*$ GVMiharp
Mínimo (K)	289,4	288,7	286,2	289,4	288,4	289,3	288,4	289,7
1er. Cuartil (K)	296,2	296,2	296,1	296,2	296,2	296,2	296,2	296,2
Mediana (K)	297,3	297,3	297,3	297,3	297,3	297,4	297,3	297,4
Media (K)	297,6	297,6	297,6	297,6	297,6	297,6	297,6	297,6
3er. Cuartil (K)	298,7	298,7	298,8	298,7	298,8	298,8	298,7	298,7
Máximo (K)	308,6	308,6	308,6	308,5	308,6	308,6	308,6	308,6
Rango (máx-mín) (K)	19,26	19,87	22,4	19,18	20,2	19,31	20,2	18,86
Desvío estándar (K)	2,20	2,24	2,34	2,22	2,26	2,24	2,26	2,23
Coef. Variación (%)	0,74	0,75	0,78	0,74	0,76	0,75	0,76	0,74
Skewness	0,77	0,71	0,57	0,74	0,68	0,70	0,69	0,73
Curtosis	1,38	1,22	0,97	1,29	1,14	1,16	1,16	1,25
RMSE (K)		0,78	1,01	0,72	0,83	0,80	0,81	0,74
RE (K)		0,00264	0,00342	0,00243	0,00279	0,00269	0,00273	0,00250
ME (K)		0,00343	0,00373	0,00279	0,01379	0,03565	0,00223	0,01531
d		0,96	0,94	0,97	0,96	0,96	0,96	0,97
RMSE/ $\sigma$		0,35	0,43	0,32	0,36	0,35	0,35	0,33

Tabla 6.1: Estadísticos comparativos entre la imagen de  $T_s$  observada y las estimadas a 1 km de resolución espacial.

De acuerdo con los descriptores estadísticos de media y mediana, los modelos de remuestreo presentaron gran semejanza con respecto a los datos observados. Es posible notar que la variabilidad térmica de los datos estimados a través del modelos  $T_s^*$  Dif. de límites presentó valores de rango cercano a la  $T_s$  observada (19,26 K con 19,18 K). El desvío estándar y el coeficiente de

variación se encuentran en el orden de 2,2 K y 0,74 % respectivamente, siendo el  $T_s^*$  Dif. de límites el que guarda mayor grado de similitud a los datos observados.

Por otra parte, el modelo  $T_s^*$  FCLS mostró la mayor amplitud en la variabilidad de la  $T_s$  con respecto a los datos de referencia, con una diferencia de 3,14 K. De forma coincidente, los valores del coeficiente de variación y el desvió estándar se incrementaron.

En la Figura 6.3 se muestran los boxplots del conjunto de datos, donde se puede notar que los valores de mediana y rango intercuartílico no varían significativamente con respecto a los datos observados. De manera generalizada, la  $T_s$  presentó gran cantidad de valores atípicos (outliers) para los valores de  $T_s$  máxima y mínima. La aparición de valores atípicos podría deberse a la presencia de píxeles cercanos a la mascara de nubes y agua con valores de estimación anómalos. Por lo tanto, este defecto no estaría vinculado con la estimacion del método, sino que depende de la calidad previa del tratamiento de los datos realizado.

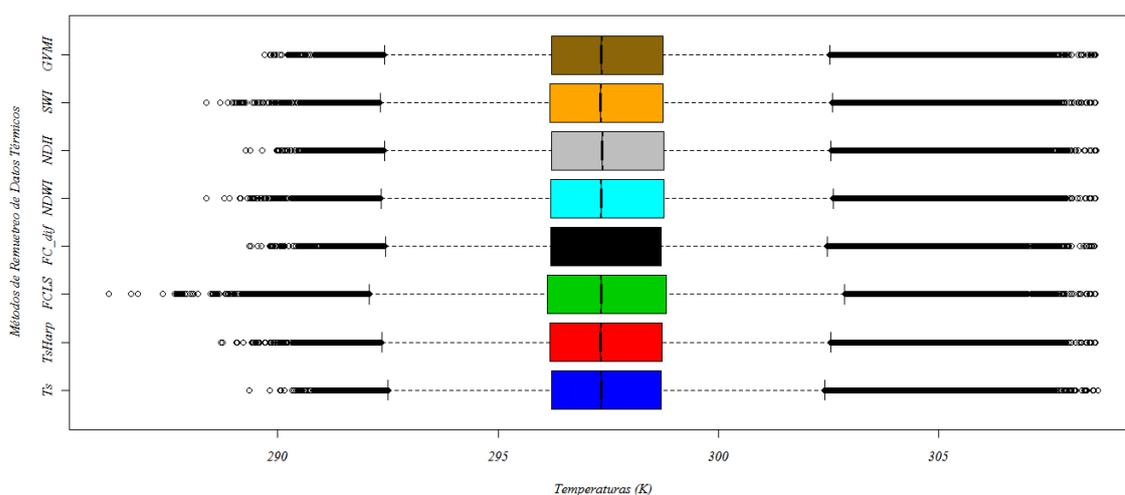
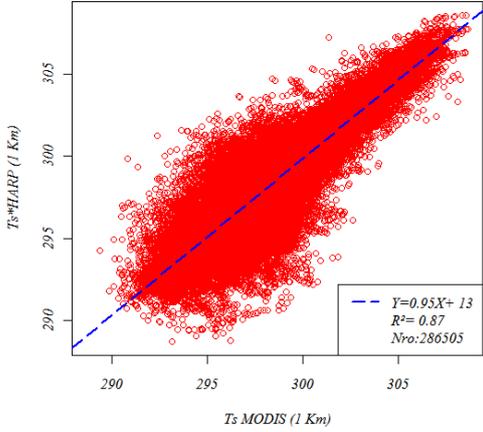


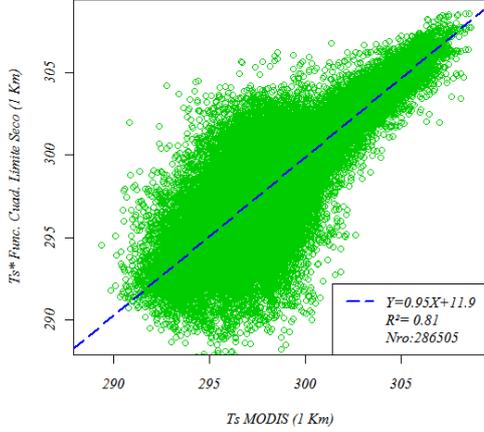
Figura 6.3: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados por los modelos:  $T_s$ HARP,  $T_s^*$ FCLS,  $T_s^*$ Dif. de límites (FC\_dif),  $T_s^*$ NDWIharp,  $T_s^*$ NDIIharp,  $T_s^*$ SWIharp,  $T_s^*$ GVMiharp.

En la Figura 6.4 se presentan los gráficos de correlación entre la variable dependiente o explicada (temperatura estimada) y la variable independiente o explicativa (temperatura observada) a una resolución de 1 km. En ésta se puede notar que en general los modelos muestran una buena aptitud y que la mayor correlación corresponde al modelo de diferencias entre límite húmedo - seco (Fig. 6.4.c) y el basado en el índice GVMI (Fig. 6.4.g), con el 89 %. Si además se consideran los estadísticos de cada modelo indicados en la Tabla 5.1, se puede notar que los modelo  $T_s^*$  Dif. de

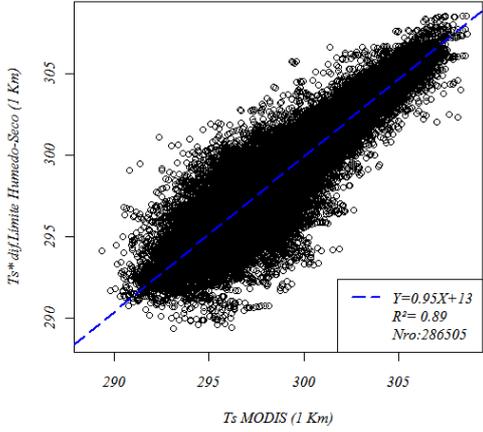
límites y  $T_s^*$  GVMlharp presentan los menores errores (RMSE), con 0,72 y 0,74 K respectivamente.



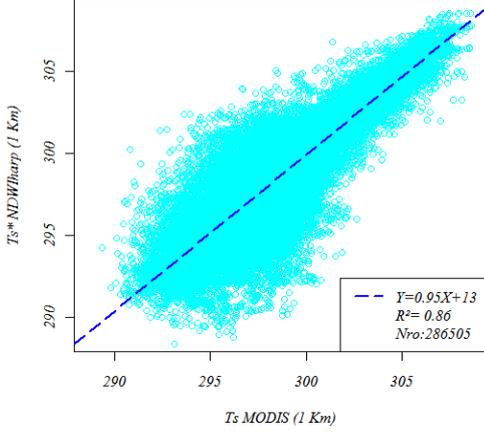
(a)



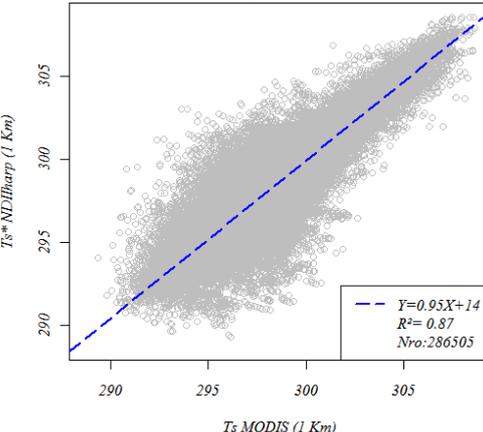
(b)



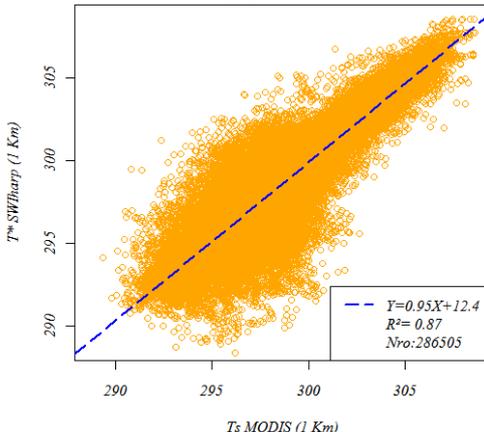
(c)



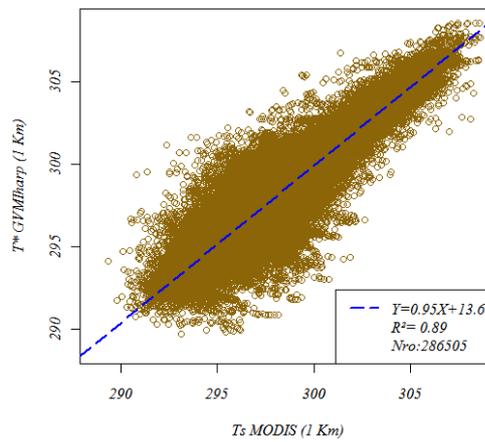
(d)



(e)



(f)



(g)

Figura 6.4: Modelos de ajuste lineal entre la  $T_s$  MODIS-Terra vs.  $T_s$  estimada por los modelos a 1km. a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s$ \*FCLS, c)  $T_s$  vs.  $T_s$ \*Dif. Límites, d)  $T_s$  vs.  $T_s$ \*NDWIharp e)  $T_s$  vs.  $T_s$ \*NDIIharp, f)  $T_s$  vs.  $T_s$ \*SWIharp g)  $T_s$  vs.  $T_s$ \*GVMIharp.

La performance del remuestreo a subpíxel se estimó en término de  $RMSE/\sigma$ , indicando que los modelos  $T_s^*$  Dif. de límites y  $T_s^*$  GVMIharp presentaron la mayor eficiencia de agregación, con 0,32 y 0,33 respectivamente. De forma coincidente, el coeficiente de concordancia de *Willmott* (d) presenta valores superiores a 0,96 (Tabla 6.1). Tomando en cuenta la desviación media del error (ME) podemos observar que los métodos basados en índices de estrés hídricos (NDWI, NDII, GVMÍ) tienden a sobreestimar el cálculo, evidenciado por los valores positivos (Tabla 6.1). En contraposición, los métodos que sólo dependen de la relación NDVI -  $T_s$  tienden a subestimar el remuestreo (valores negativos) (Tabla 6.1).

La Figura 6.5 muestra el mapa de  $T_s$  observada a partir de la imagen MODIS (Fig. 6.5 a) y los mapas de  $T_s$  estimadas a partir de los modelos propuestos (Fig. 6.5 b-h). De acuerdo a los mapas elaborados es posible notar que los valores de  $T_s$  simulados guardan una estrecha similitud con respecto a los datos observados. Sin embargo, para los valores máximos de  $T_s$  se indica un mayor grado de disparidad en la representación de los datos.

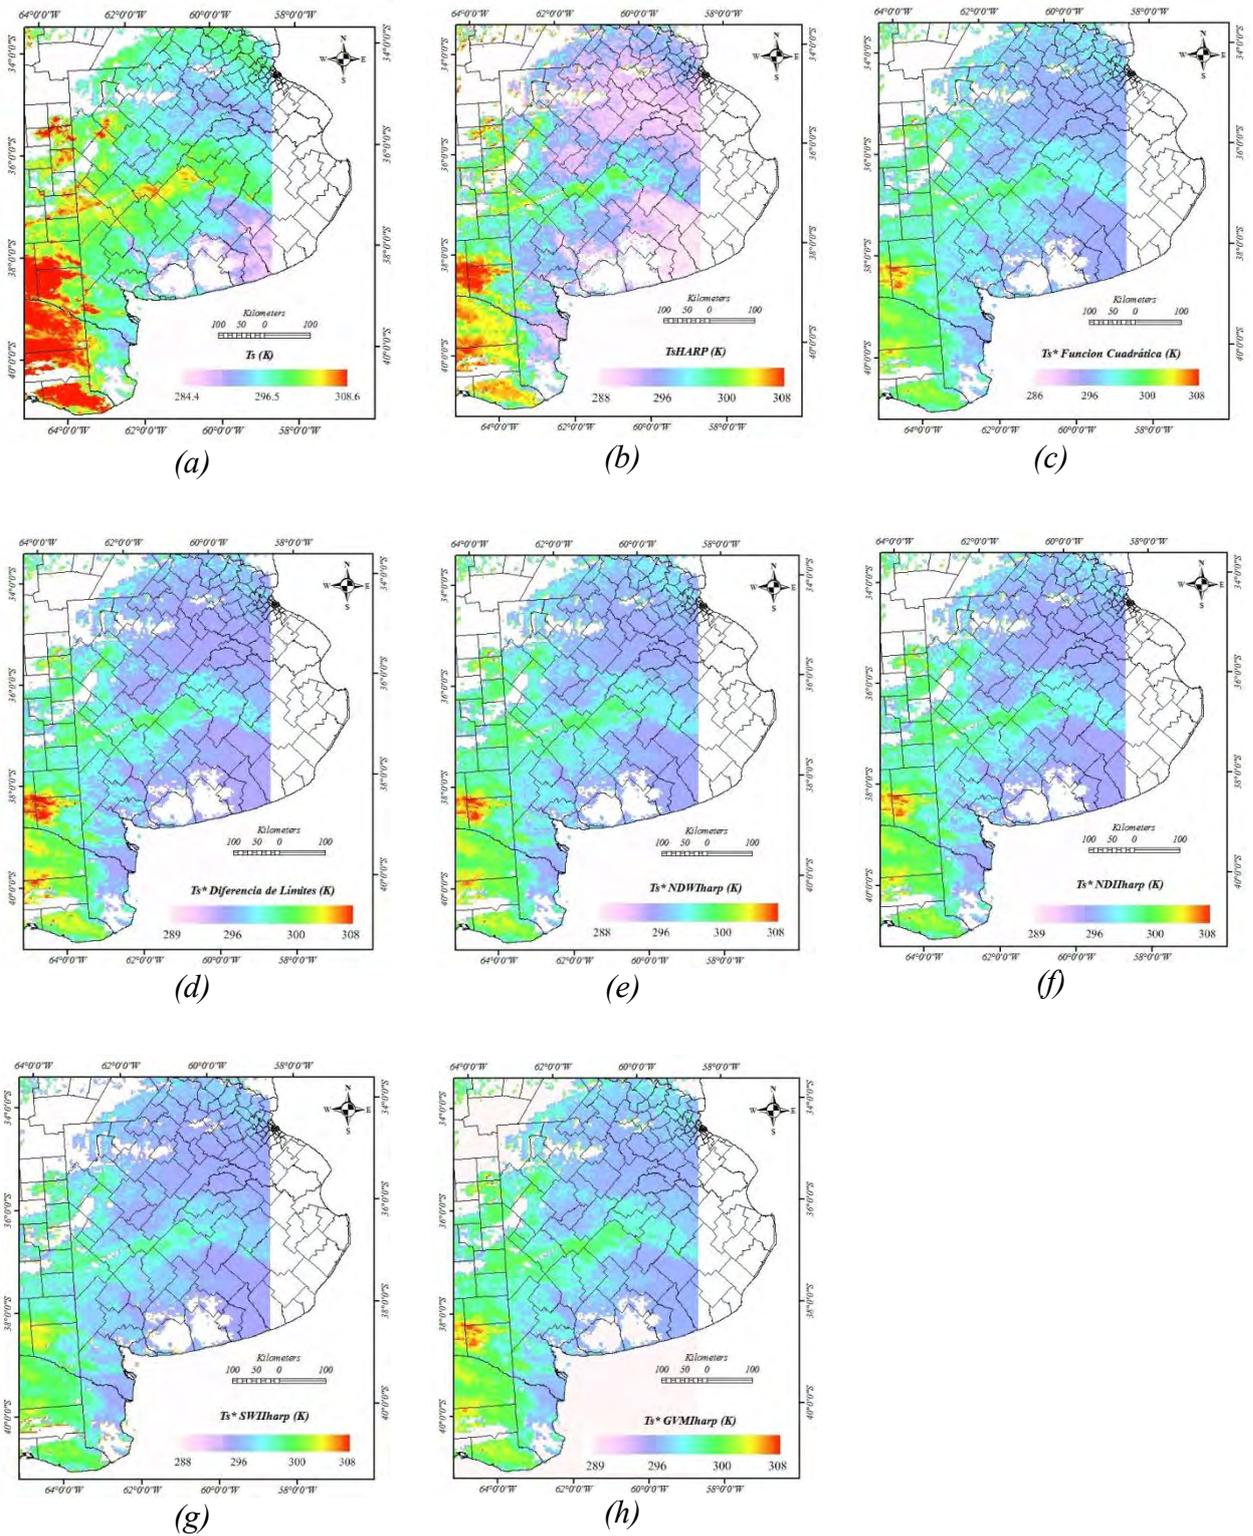
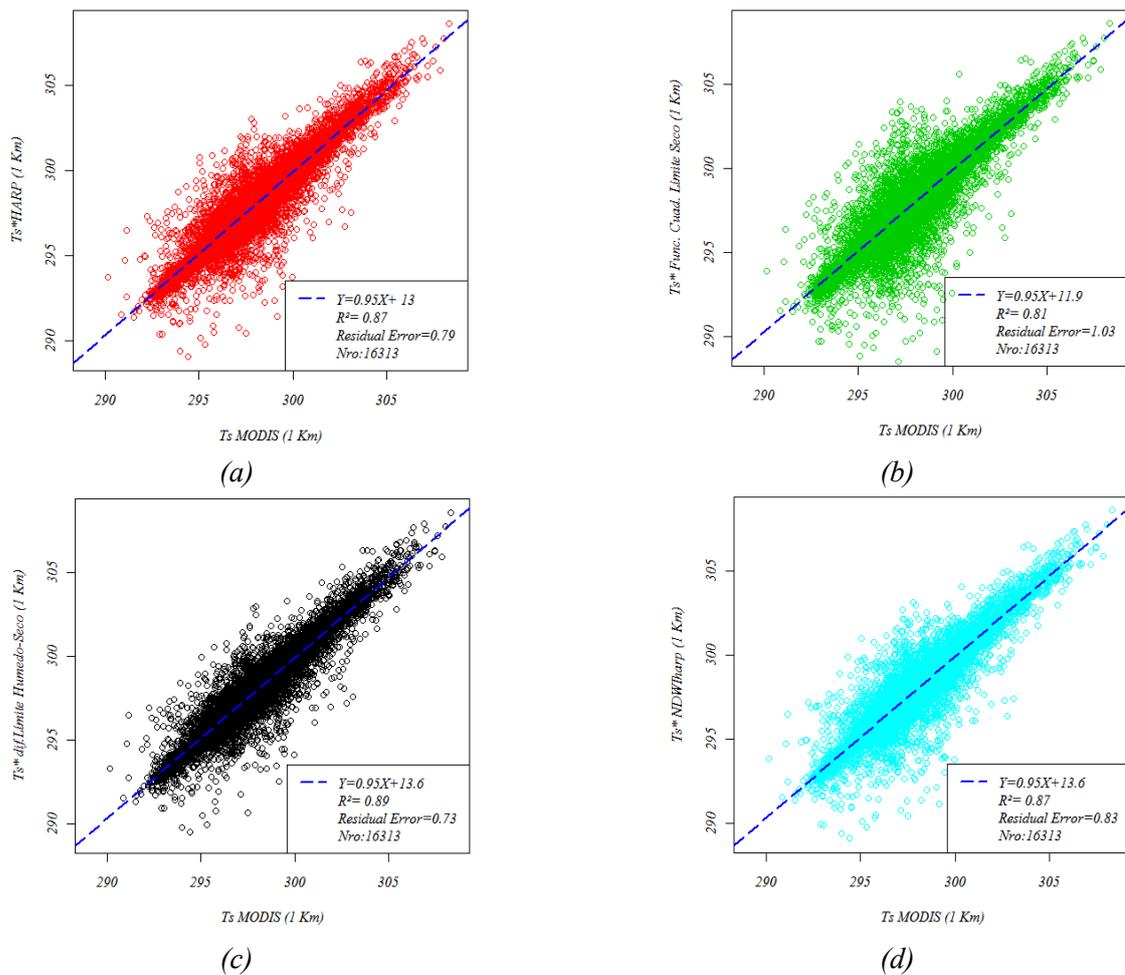


Figura 6.5: Mapas de Temperatura de superficie observada. a) imagen MODIS-Terra (1km) y mapas de temperatura estimadas por diferentes modelos (1km), b)  $T_s$ HARP, c)  $T_s$ \*FCLS, d)  $T_s$ \*Dif. de Límites, e)  $T_s$ \*NDWIharp, f)  $T_s$ \*NDIharp, g)  $T_s$ \*SWIharp, h)  $T_s$ \*GVMharp.

En lugar de realizar un análisis de los modelos para todos los datos disponibles es apropiado seleccionar muestras de un tamaño que resulte adecuado para la validación de los modelos. Una

alternativa para lograr muestras homogéneas y representativas es la técnica geostatística de semivariograma que permite disponer de datos de  $T_s$  con independencia espacial (Miller et al., 2010). Se indica un intervalo de distancia de 20 km para los datos MODIS resultado de considerar el valor promedio de las orientaciones geográficas N-S y E-O en la imagen. Esta distancia se utilizó para seleccionar píxeles aleatoriamente usando la herramienta de generación de datos para testeo del software ENVI 4.7; a partir del cual se extrajo una muestra correspondiente al 5 % de los píxeles de la imagen completa.

En la Figura 6.6 se presentan los modelos de ajuste resultado de la comparación entre la  $T_s$  observada y estimadas para la muestra de 16.313 píxeles extraídos de la imagen MODIS Terra utilizando el semivariograma. De acuerdo a los resultados, se observa que los  $R^2$  son semejantes a los logrados en el análisis global (Fig. 6.4). De este modo el muestreo de datos a partir de la técnica de semivariograma permite validar los modelos de regresión de forma más consistente.



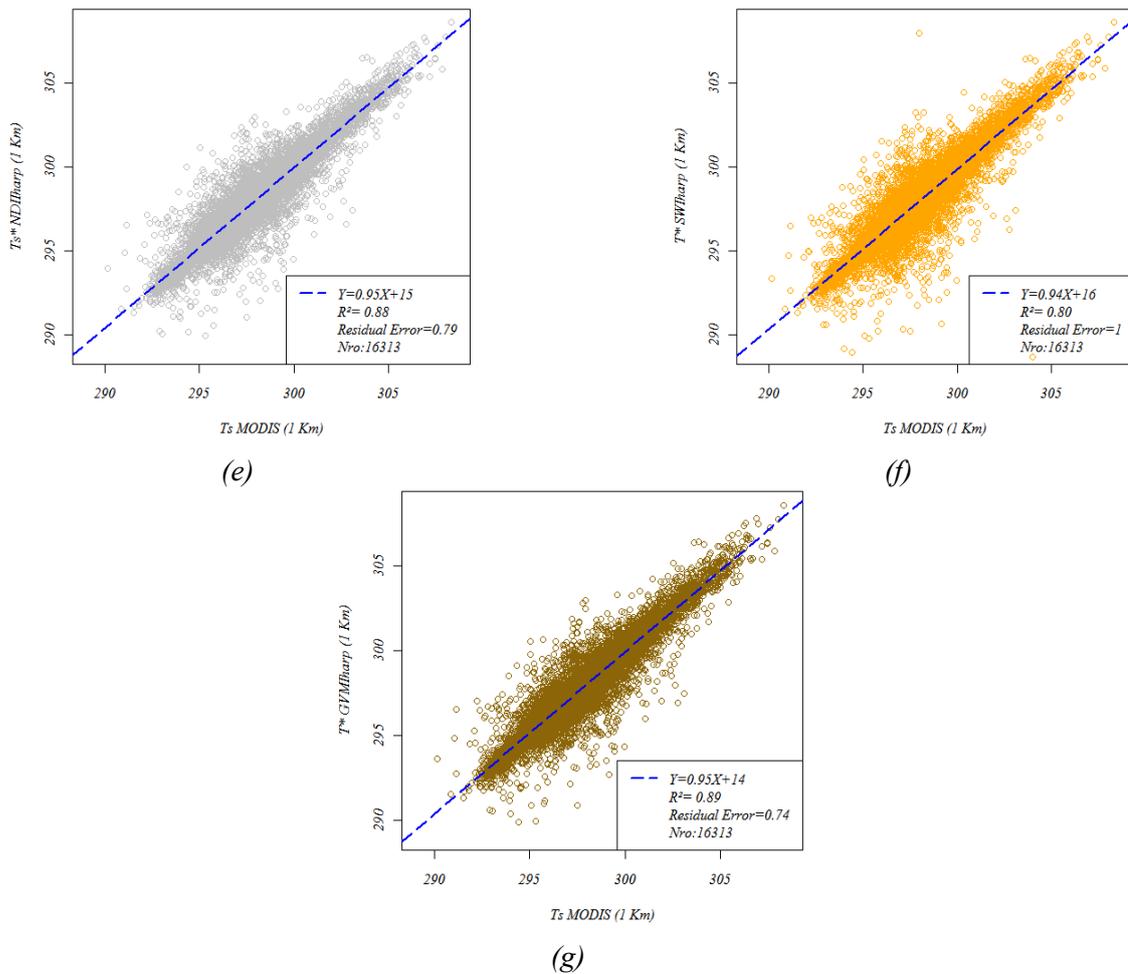


Figura 6.6: Modelos de ajuste lineal entre la  $T_s$  MODIS - Terra vs.  $T_s$  estimada por los modelos a 1 km, aplicando muestreo aleatorio de datos térmicos para toda la imagen. a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s$ \*FCLS, c)  $T_s$  vs.  $T_s$ \*Dif. Límites, d)  $T_s$  vs.  $T_s$ \*NDWIharp e)  $T_s$  vs.  $T_s$ \*NDIharp, f)  $T_s$  vs.  $T_s$ \*SWIharp g)  $T_s$  vs.  $T_s$ \*GVMharp.

## 6.2. EVALUACIÓN DE LOS MODELOS EN UN ÁREA CON ALTA PROPORCIÓN DE VEGETACIÓN

Desde el punto de vista aplicado suele ser de relevancia estudiar áreas de alta cobertura vegetal o con máxima proporción de suelo desnudo. Entonces, se hace necesario evaluar los métodos en relación al tipo de cobertura. A continuación se evalúan los modelos de remuestreo observando el comportamiento sobre diferentes cubiertas para la imagen MODIS Terra del 23/02/2010. Se evaluó la metodología para suelos con alto porcentaje de superficie cubierta por vegetación natural y para cobertura parcial y suelo desnudo en diferentes regiones de interés.

En la Figura 6.7 se observa la región de interés con una proporción de vegetación mayor al 70 % que equivale a 10.120 km<sup>2</sup> dentro de la escena de la provincia de Buenos Aires.

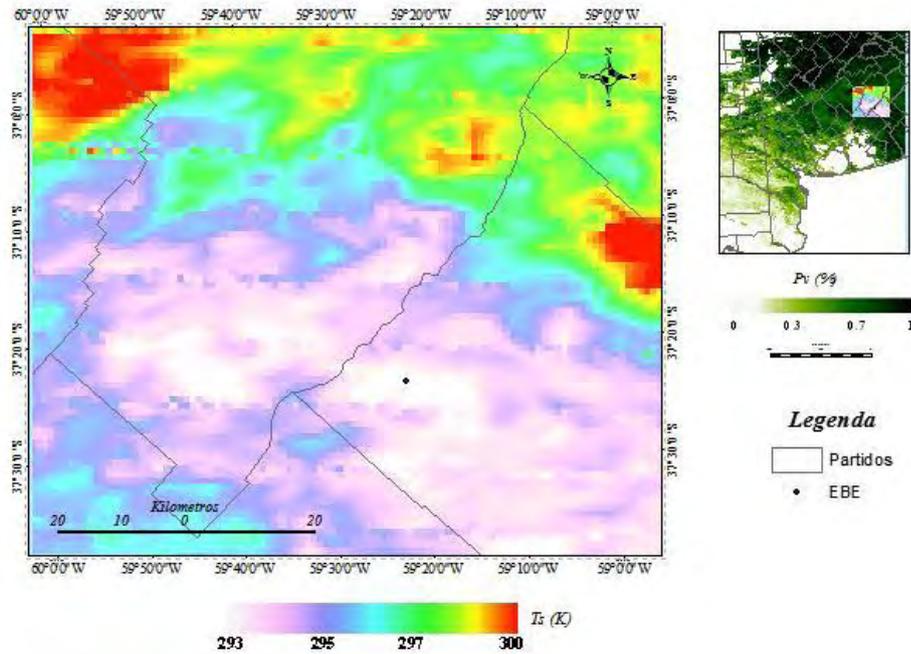


Figura 6.7: Mapa de  $T_s$  en área con alta cobertura vegetal y mapa de  $P_v$  (esquina superior derecha).

Los estadísticos descriptivos del conjunto de datos considerados son resumidos en la Tabla 6.2. Se observan variaciones poco significativas entre los valores estimados por los modelos de agregación a partir de lo indicado por los valores de rango, desvío estándar y coeficiente de variación. Sin embargo, según muestra la Tabla 6.2, el valor de rango que guarda mayor semejanza en comparación con lo observado son indicados por el modelo  $T_s^*$  Dif. de límites, con 6,34 K.

Estadísticos	$T_s$ MODIS (1 Km)	$T_s$ HARP	$T_s^*$ FCLS	$T_s^*$ Dif. de Límites	$T_s^*$ NDWIharp	$T_s^*$ NDIIharp	$T_s^*$ SWIharp	$T_s^*$ GVMharp
Mínimo (K)	293,4	293,5	292,4	293,5	293,5	293,3	293,5	293,4
1er. Cuartil (K)	294,9	294,9	295,0	295,0	295,0	295,0	294,9	295,0
Mediana (K)	296,0	296,1	296,1	296,1	296,1	296,1	296,1	296,1
Media (K)	296,2	296,2	296,2	296,2	296,3	296,3	296,2	296,3
3er. Cuartil(K)	297,5	297,5	297,6	297,5	297,6	297,6	297,6	297,6
Máximo(K)	299,7	300,6	302,5	299,8	301,8	301,7	301,0	300,7
Rango (máx-mín) (K)	6,34	7,15	10,01	6,3	8,32	8,44	7,48	7,26
Desvío estándar (K)	1,46	1,46	1,52	1,46	1,48	1,47	1,47	1,47
Coef. Variación (%)	0,49	0,49	0,51	0,49	0,5	0,49	0,49	0,49
Skewness	0,249	0,241	0,232	0,227	0,274	0,237	0,255	0,228
Curtosis	-1,08	-1,09	-0,87	-1,12	-0,99	-1,02	-1,06	-1,08
RMSE (K)		0,35	0,42	0,39	0,36	0,43	0,33	0,40
RE (K)		0,0023	0,0028	0,0015	0,0018	0,00184	0,0011	0,0022
ME (K)		0,0352	0,0398	0,0334	0,0579	0,07192	0,0399	0,0526
d		0,98	0,97	0,98	0,98	0,97	0,98	0,98
RMSE/ $\sigma$		0,24	0,27	0,26	0,24	0,29	0,22	0,27

Tabla 6.2: Estadísticos comparativos entre la imagen de  $T_s$  observada y las estimadas a 1 km de resolución espacial.

Según lo indicado de la Tabla 6.2, la asimetría de la distribución de los datos térmicos para el conjunto de los modelos empleados presenta sesgo hacia la izquierda de la media aritmética (skewness positivo). Los valores negativos de curtosis y el histograma de frecuencia normalizada presentado en el Figura 6.8 indican que la distribución de los datos es binomial. Se comprobó la normalidad de los datos muestreados aplicando los test *Kolmogorov - Smirnov* y *Chi - Cuadrado* para un intervalo de confianza de 95 %. El valor indicado por el estadístico p-valor ( $2,22 \cdot 10^{-16}$ ) sugiere que no existe evidencia significativa para aceptar la hipótesis de normalidad.

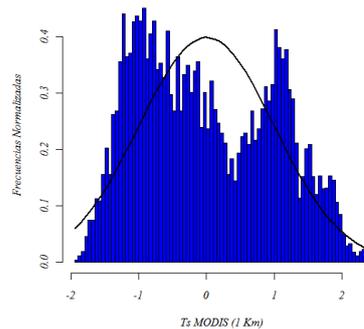


Figura 6.8: Histogramas de frecuencias normalizadas para los datos observados de  $T_s$ .

La Figura 6.9 se presentan los boxplots de los datos contenidos en la muestra, donde se observa una alta simetría de las cajas y bigotes con poca presencia de valores atípicos, indicando diferencias pocos significativas en los valores estimados.

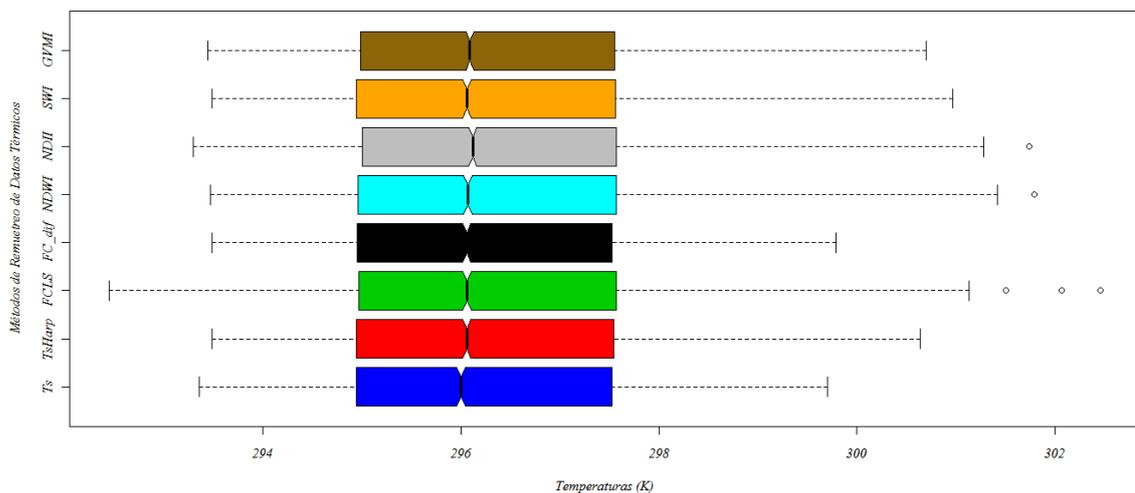
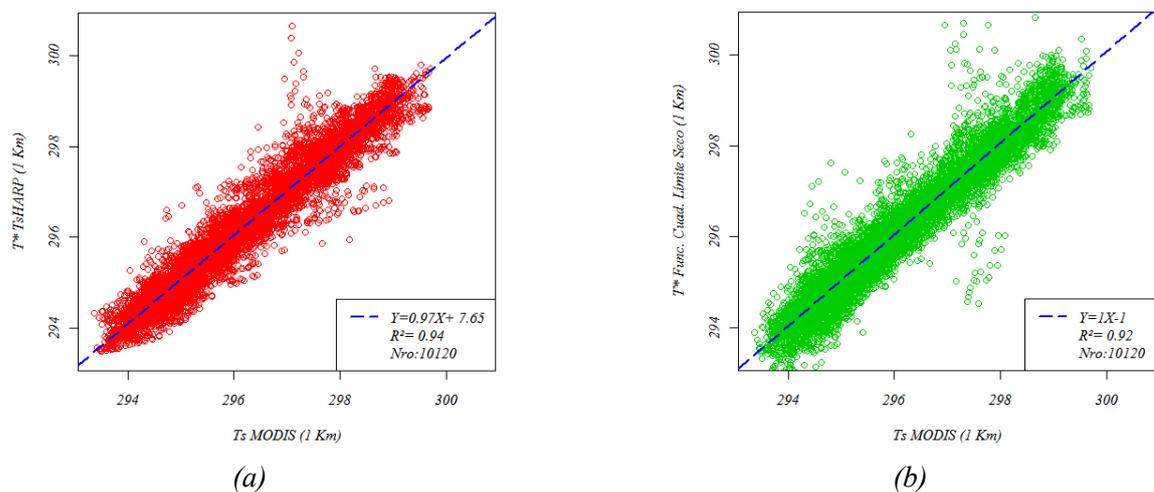


Figura 6.9: Boxplots de los datos térmicos obserbados ( $T_s$ ) y estimados:  $T_s$ HARP,  $T_s$ \*FCLS,  $T_s$ \* Dif. de límites (FC\_dif),  $T_s$ \*NDWIharp,  $T_s$ \*NDIIharp,  $T_s$ \*SWIharp,  $T_s$ \*GVMlharp.

El modelo  $T_s$ HARP, el  $T_s$ \*NDWIharp y el  $T_s$ \*SWIharp presentan los menores errores en la estimación de la  $T_s$ , con RMSE de 0,35 - 0,36 y 0,33 y RE de 0,0023-0,0018 y 0,0011 respectivamente. De forma coincidente con los resultados mostrados anteriormente, el RMSE/ indica que los métodos citados poseen la mejor performance, con 0,24 y 0,22 respectivamente. Según lo indicado en la Tabla 6.2, los resultados mostrados por el índice de concordancia de *Willmott* (d) permanece invariante y los valores positivos de ME evidencian que la mayoría de los modelos aplicados sobrestiman la  $T_s$ .

En la Figura 6.10 se presentan los ajustes lineal entre la  $T_s$  observada y estimada para los diferentes modelos de agregación a una resolución de 1 km. También se observa que la totalidad de los modelos analizados poseen un alto porcentaje de datos correlacionados para las variables consideradas (> 90 %). Los modelos  $T_s$ HARP, el  $T_s$ \*NDWIharp y el  $T_s$ \*SWIharp presentaron los mejores ajustes en término del  $R^2$ , con 0,94. Es de destacar que dos de los modelos ( $T_s$ HARP,  $T_s$ \*SWIharp), utilizan sólo parámetros extraídos del espacio contextual NDVI -  $T_s$ . Es importante tener en consideración que se puede obtener buena agregación a nivel de subpíxel de los datos térmicos para zonas con alta proporción de vegetación utilizando modelos parametrizados únicamente en el diagrama NDVI- $T_s$ .



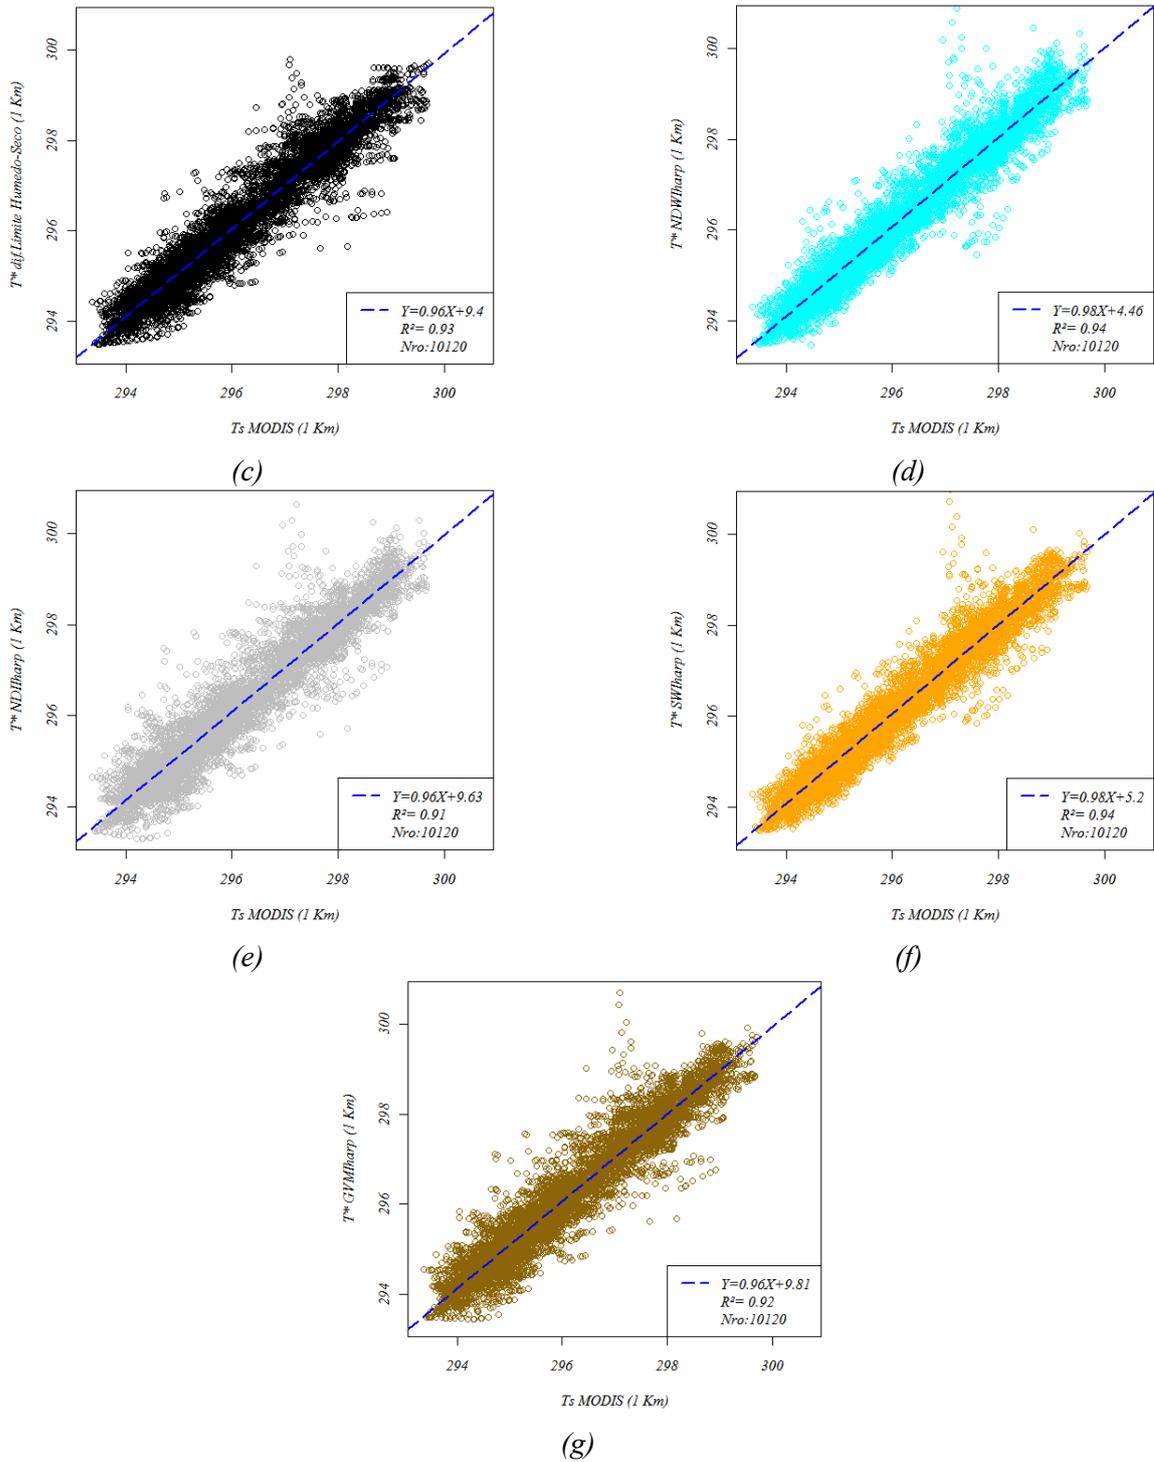


Figura 6.10: Modelos de ajuste lineal entre la  $T_s$  MODIS-Terra vs.  $T_s$  estimada por los modelos a 1km en el área con alta proporción de vegetación. a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s$ \*FCLS, c)  $T_s$  vs.  $T_s$ \*Dif. Límites, d)  $T_s$  vs.  $T_s$ \*NDWIharp e)  $T_s$  vs.  $T_s$ \*NDIIharp, f)  $T_s$  vs.  $T_s$ \*SWIharp g)  $T_s$  vs.  $T_s$ \*GVMIharp.

### 6.3. EVALUACIÓN DE LOS MODELOS EN UN ÁREA CON BAJA PROPORCIÓN DE VEGETACIÓN

Para evaluar el comportamiento del remuestreo de datos térmicos sobre suelo desnudo, se seleccionó un área con reducida cobertura vegetal dentro de la escena correspondiente al sureste de la provincia de La Pampa, comprendiendo a los partidos de Lihuel Calel, Huacal y Caleu Caleu (4.874 km<sup>2</sup>) (Fig. 6.11).

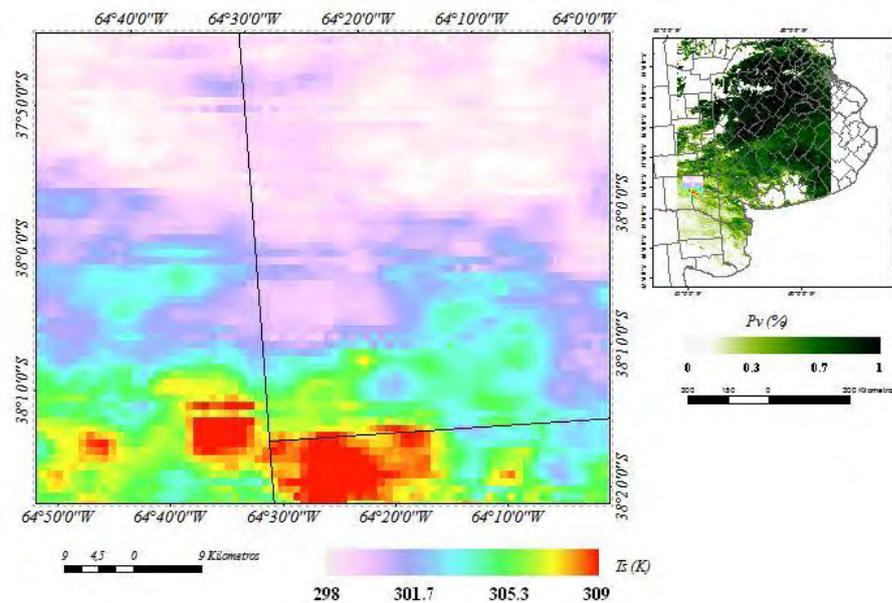


Figura 6.11: Mapa de  $T_s$  en área con baja proporción de vegetación y mapa de  $P_v$  (esquina superior derecha).

Los modelos de remuestreo subpíxel fueron implementados para la región seleccionada sobre la imagen MODIS Terra del 23/02/2010. Sobre la base de las funciones presentadas en la Figura 6.1 (a, b, c), se siguió el esquema metodológico presentado en la Figura 4.2.

En la Tabla 6.3 se presentan los resultados estadísticos del remuestreo de datos térmicos para la región de suelos con baja proporción de vegetación presentada en la Figura 5.11. En función a los valores de  $T_s$  indicados en la Tabla 6.3 es posible notar que la variabilidad térmica de la región de interés se incrementó significativamente con respecto a los datos presentados para zonas con alta proporción de vegetación (Tabla 6.2). Esta variación es típica de zonas con suelo desnudo húmedo y seco. Además, muestra alta similitud entre los estadísticos descriptivos de los datos observados y estimados, con media aritmética de 301,5 K para el conjunto de modelos y rangos de temperatura entre 10,84 y 11,34 K. Se nota que el modelo  $T_s^*GVMiharp$  presenta una variabilidad térmica similar a los datos observados.

Estadísticos	$T_s$ MODIS (1 Km)	$T_s$ HARP	$T_s^*$ FCLS	$T_s^*$ Dif. de Límites	$T_s^*$ NDWIharp	$T_s^*$ NDIharp	$T_s^*$ SWIharp	$T_s^*$ GVMiharp
Mínimo (K)	297,8	297,6	297,0	297,8	297,3	297,2	297,6	297,7
1er. Cuartil (K)	299,3	299,3	299,3	299,3	299,3	299,3	299,3	299,3
Mediana (K)	301,0	301,0	301,0	301,0	301,0	301,0	301,0	301,0
Media (K)	301,5	301,5	301,5	301,5	301,5	301,5	301,5	301,5
3er. Cuartil (K)	303,4	303,5	303,5	303,4	303,5	303,5	303,5	303,5
Máximo (K)	308,6	308,6	308,6	308,5	308,6	308,6	308,6	308,6
Rango (máx-mín) (K)	10,87	10,93	11,61	10,69	11,27	11,34	10,97	10,84
Desvío estándar (K)	2,48	2,49	2,51	2,49	2,51	2,51	2,50	2,49
Coef. Variación (%)	0,82	0,82	0,83	0,82	0,83	0,83	0,82	0,82
Skewness	0,57	0,53	0,49	0,54	0,50	0,50	0,52	0,53
Curtosis	-0,73	-0,79	-0,79	-0,78	-0,79	-0,79	-0,79	-0,79
RMSE (K)		0,66	0,69	0,67	0,68	0,68	0,66	0,66
RE (K)		0,0022	0,0023	0,0022	0,0022	0,0022	0,0022	0,0021
ME (K)		-0,013	-0,020	-0,007	-0,022	-0,016	-0,013	-0,0083
d		0,98	0,98	0,98	0,98	0,98	0,98	0,98
RMSE/ $\sigma$		0,26	0,27	0,27	0,27	0,27	0,26	0,26

Tabla 6.3: Estadísticos comparativos entre la imagen de  $T_s$  observada y las estimadas a 1 km de resolución espacial.

En la Figura 6.12 se muestran los boxplots de la muestra de suelo seleccionada donde es posible observar la semejanza en los valores de mediana y tamaño de las cajas, caracterizado por ausencia de valores atípicos (en zonas semiáridas no se observan por lo general efectos de cuerpos de agua y exista baja probabilidad de presencia de nubes).

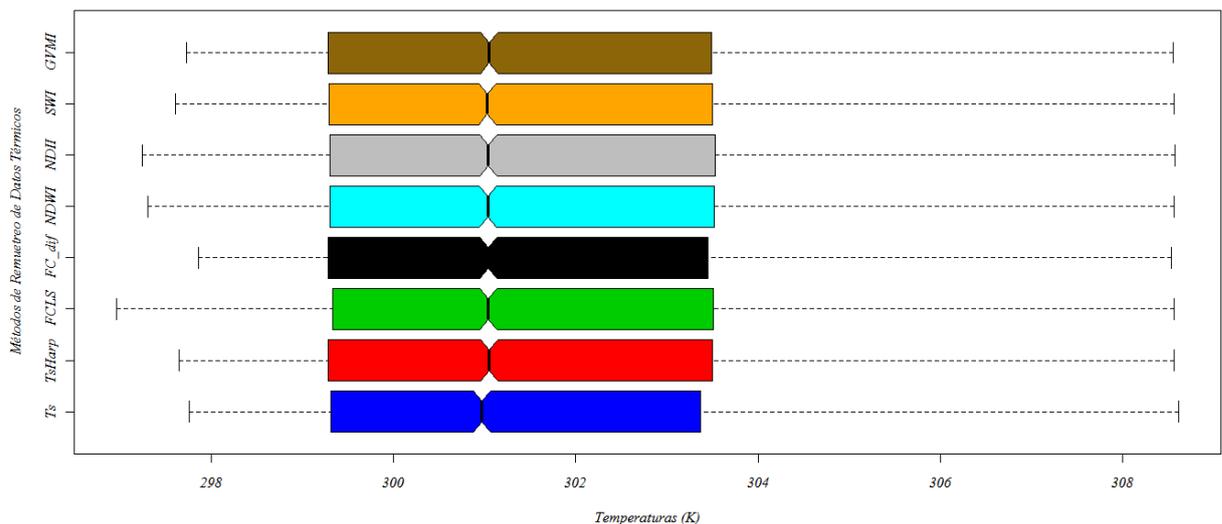


Figura 6.12: Boxplots de los datos térmicos observados ( $T_s$ ) y estimados:  $T_s$ HARP,  $T_s^*$ FCLS,  $T_s^*$  Dif. de límites ( $FC\_dif$ ),  $T_s^*$ NDWIharp,  $T_s^*$ NDIharp,  $T_s^*$ SWIharp,  $T_s^*$ GVMiharp

Por otro lado, la distribución de los datos muestra simetría con sesgo hacia la izquierda de la media aritmética (skewness positiva). En la Figura 6.13 se muestra el histograma de frecuencia

normalizada indicando la densidad de los punto observados, donde se puede notar que la distribución de los mismos no indican una tendencia normal.

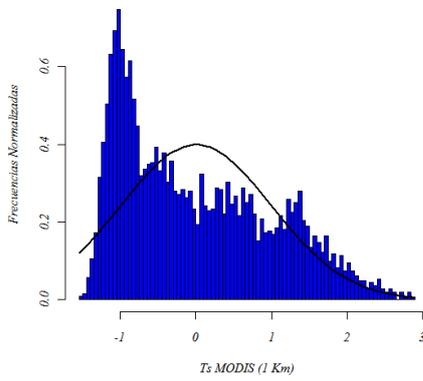
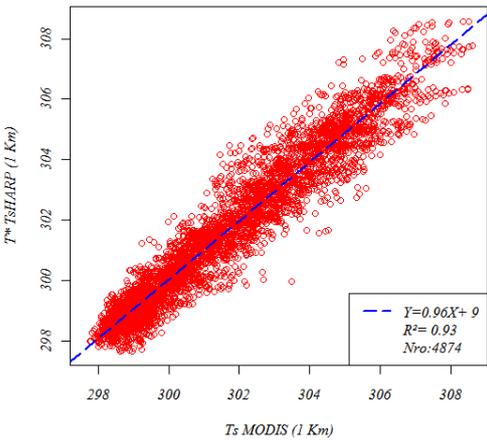
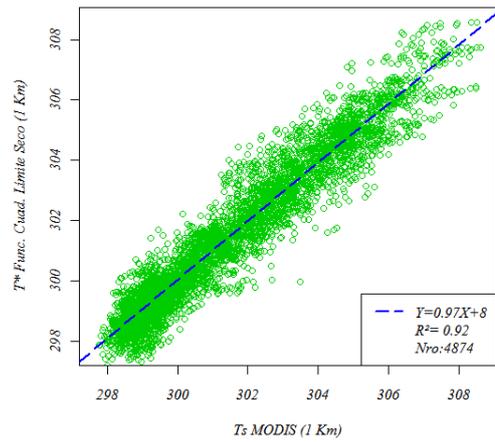


Figura 6.13: Histogramas de frecuencias normalizadas para la  $T_s$  en área con baja cobertura vegetal.

En la Figura 6.14 se presentan los modelos de ajuste entre la  $T_s$  observada y estimada a partir de los modelos de remuestreo. Los ajustes indican que la totalidad de los modelos lograron predecir entre el 91 y 93 % de las estimaciones de  $T_s$ . Puntualmente, el  $R^2$  y RMSE/ muestran que los modelos TsHARP y el  $T_s$ \*GVMiharp obtuvieron la mayor precisión en la agregación de los datos, con 0,93 y 0,26 respectivamente. En término del RMSE (0,66 K) y RE (0,0022 K) los modelos TsHARP y el  $T_s$ \*GVMiharp obtuvieron los menores errores estadísticos.



(a)



(b)

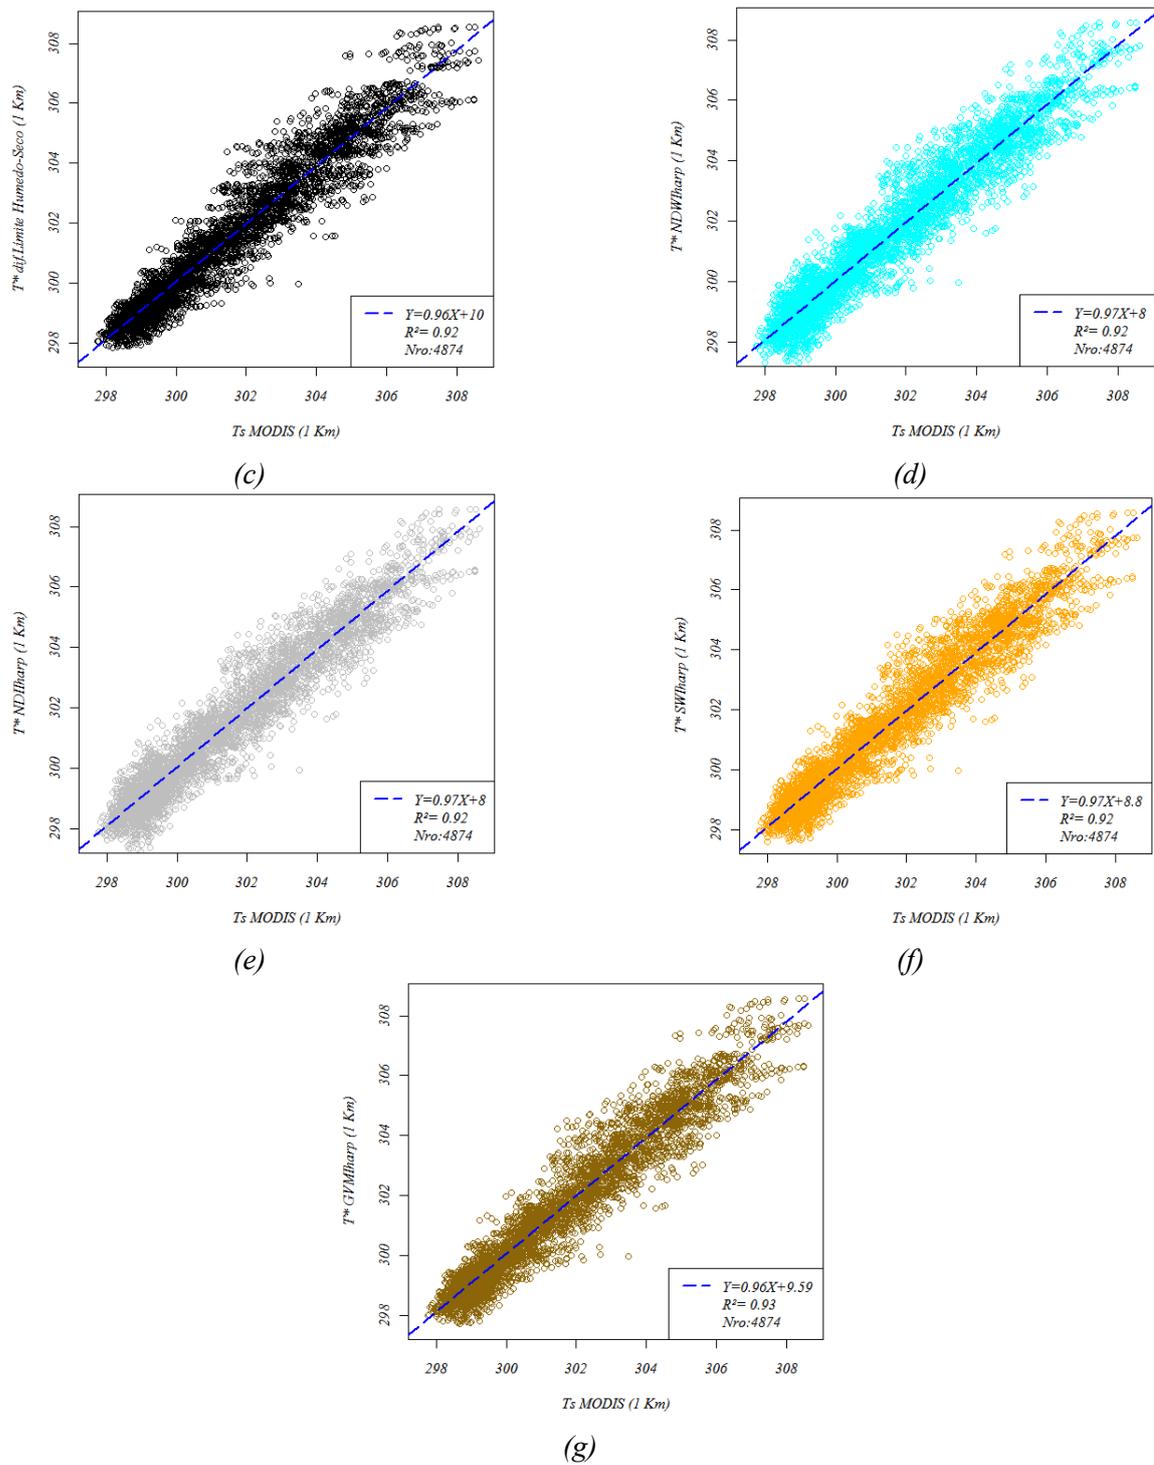


Figura 6.14: Modelos de ajuste lineal entre la  $T_s$  MODIS-Terra vs.  $T_s$  estimada por los modelos a 1km en área con reducida proporción de vegetación (4756 píxeles). a)  $T_s$  vs.  $T_s$ HARP, b)  $T_s$  vs.  $T_s$ \*FCLS, c)  $T_s$  vs.  $T_s$ \*Dif, Limites, d)  $T_s$  vs.  $T_s$ \*NDWIharp e)  $T_s$  vs.  $T_s$ \*NDIIharp, f)  $T_s$  vs.  $T_s$ \*SWIharp g)  $T_s$  vs.  $T_s$ \*GVMharp.

## Capítulo VII - VALIDACIÓN DE MODELOS

Considerando la buena performance mostrada por el modelo  $T_s^*$  Dif. de límites, para diferentes resoluciones y condiciones de superficie, se realizó la validación con medidas *in situ* de la EBE y con datos de las campañas previas de validación (*Tesis de Máster; Vazquez, 2008*) realizadas en el ámbito del Instituto de Hidrología de Llanuras. Entonces, para la validación de la información correspondiente a la captura de las 14:45 am del día juliano 54 de 2010 se utilizaron los datos registrados por el sensor CG3 de la estación de BE y el sensor IRR-P térmico (Establecimiento Laura Leufú; 37° 14'S, 59° 34'O). Estos sensores se ubican en una parcela con cobertura de soja de primera en la que la estación se ubica en el medio del predio con la configuración indicada en el capítulo 3. La Figura 7.1 muestra el comportamiento de la temperatura radiativa de la cubierta de soja para las 24 horas del día juliano 54 con resolución temporal de 15 minutos. Además se puede notar la diferencia entre la  $T_s$  en el momento de paso de la misión Landsat y de la misión EOS - Aqua (1 K en el caso analizado en la *Fig. 7.1*). Para la validación se tomó el dato de  $T_s$  registrado al momento de la captura de la imagen considerando las correcciones correspondientes de emisividad del cultivo.

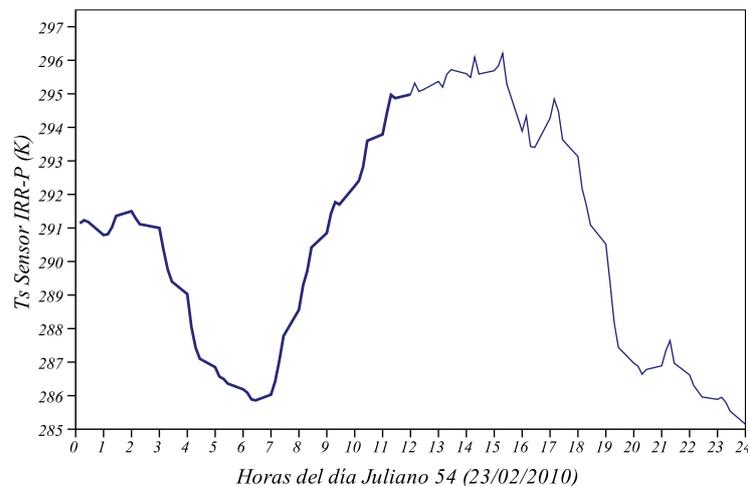


Figura 7.1: Variación diaria de la temperatura captada por el sensor IRR-1505 de la CNR 1.

Dado que la parcela presenta condiciones óptimas de fertilidad y no se observan variaciones significativas en la disponibilidad de agua en el suelo (observada por la alta reflectividad en el IRC e IRM) se considera que el valor de  $T_s$  (y el error propio del sensor) registrado es representativo y que el mismo puede compararse con el logrado luego del remuestreo. Al comparar los resultados en el píxel en el que se encuentra la estación se observa que la  $T_s$  fue de 294,87 K y el logrado del

remuestreo MODIS fue de 293,93 K; mientras que para Landsat el valor fue de 292,90 K. La baja variación es consecuencia de la alta homogeneidad en la parcela bajo estudio.

La validación de los datos térmicos remuestreados proveniente de IS MODIS Terra (10/11/2006) y Landsat TM (11/11/2006) se realizó a partir de una colección de datos obtenidos en forma de transecta en el marco de la validación de Índices de Estrés Hídrico por Vázquez (2008). La transecta fue realizada en una parcela con trigo ubicada en la unidad productiva llamada “Tata Dios” (*línea amarilla; Fig. 7.2*). Se identificaron los puntos de medición a partir de coordenadas GPS (Global Positioning System) en latitud/longitud con el elipsoide WGS 84, en un área de interés de 10 ha. Se realizaron 38 observaciones *in situ* de la  $T_s$  cada 10 m utilizando un radiómetro IRT portátil marca EVEREST, entre las 11 y 12:45 am.

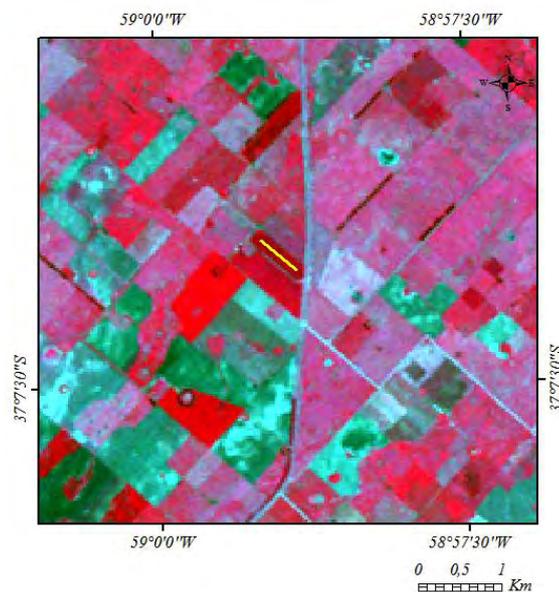


Figura 7.2: Recorte de la imagen captada por el sensor TM del día 11/11/2006 (RGB 432) y transecta de validación (en amarillo).

La Figura 7.3 muestra la distribución de los valores de  $T_s$  para la transecta identificada en terreno, la derivada de la IS MODIS Terra y Landsat TM remuestreadas las imágenes a 30 m de resolución espacial. Fue posible comparar los datos remuestreados con las medidas de terreno a partir de agrupar las 38 observaciones cada 3 medidas y conformar de esta manera el valor promedio de un píxel de 30 m. Sin embargo, es importante aclarar que el área que toma la imagen MODIS no se corresponde con píxeles cubiertos por trigo, sino que, el resultado del remuestreo de  $T_s$  de la imagen de 1 km corresponde a la parcela de interés y a las aledañas (de menor cobertura vegetal) y por lo tanto, no representativa de las condiciones de una cubierta vegetal. Tal como se observa en la

Figura 7.3 los valores de remuestreo de MODIS se encuentran muy por encima de los correspondientes al cultivo de trigo. De acuerdo a medidas de  $T_s$  realizadas por Vazquez (2006), en suelos completamente desnudos o con nula cubierta vegetal, los valores pueden superar los 300 K a la hora de paso del satélite (Fig. 7.3 línea punteada negra). Por lo tanto la diferencia no se debe al método de remuestreo aplicado sino que se debe a que el área presentaba características no adecuadas para la resolución de MODIS y por ello las medidas de terreno no son representativas de las de satélite.

En cuanto al comportamiento observado con Landsat TM el valor medio logrado con el método  $T_s^*$  Dif. de límites es de  $292,58 \text{ K} \pm 0,9$  y el correspondiente a la transecta es de  $291,37 \text{ K} \pm 1,1$ . Si bien a escala puntual los valores muestran una variabilidad que puede ser considerada significativa no lo es así a escala de parcela y por lo tanto el método es óptimo a la escala de trabajo considerada (10 ha) (Fig. 7.3 línea guion azul y línea llena naranja).

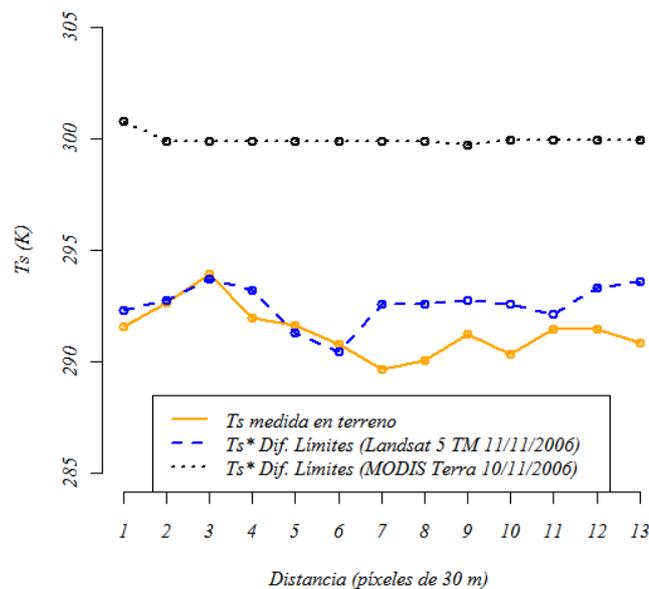


Figura 7.3:  $T_s$  (K) en los puntos de la transecta de terreno y los logrados con el método  $T_s^*$  Dif. de límites.

***PARTE IV***

***CONSIDERACIONES FINALES y RECOMENDACIONES***

## **CONSIDERACIONES FINALES**

Se evaluaron seis modelos de remuestreo de datos térmicos que utilizan y combinan información espacial de las misiones satelitales MODIS Terra y Landsat TM utilizando el diagrama NDVI -  $T_s$  como base contextual. El NDVI y la  $T_s$  como variables biofísicas que intervienen el balance de energía, son clave en la precisión de los modelos de remuestreo empíricos. Si bien es válido utilizar datos térmicos sin pre-procesamiento, la certeza final del modelo aplicado está en relación directa con correcta estimación de las variables que integran el dicho espacio.

La forma de identificar los límites seco y húmedo condiciona significativamente la precisión de los modelos basados en la relación NDVI- $T_s$ . Entonces, se sugiere profundizar el estudio de la función cuadrática como forma de identificar el límite seco del diagrama NDVI- $T_s$  ya que éste representa el proceso físico metabólico con un límite máximo (punto máximo de la función cuadrática) que no representa la función lineal.

Esta investigación mostró que los modelos de remuestreo de datos considerados son útiles para representar patrones espaciales de  $T_s$  con razonable precisión dentro de cada píxel MODIS y Landsat TM sobre la región sub-húmeda pampeana. Sin embargo, la región presenta una gran heterogeneidad de uso del suelo a escala de parcela, representada por diferentes tipos de cultivos y estadios de crecimiento. Se observó que los datos térmicos presentan una alta dispersión para los valores de  $T_s$  más bajos, característicos de zonas con vegetación en buenas condiciones hídricas. Esto permite pensar que en estudios de estrés hídrico no tendría relevancia estimar con precisión la  $T_s$  para valores bajos, siendo factible el uso de modelos que tengan alta dispersión en valores bajos y baja dispersión para valores altos de  $T_s$ .

Estudios recientes, muestran que los errores producidos por los modelos  $T_s$ HARP son del orden de los 2 a 3 K (Kustas *et al.*, 2003; Agam *et al.*, 2007 (a-b); Mukherjee, 2008; Wang y Liang, 2009; Chan *et al.*, 2010; Jeganathana *et al.*, 2011; Yang *et al.*, 2011); mientras que los modelos propuestos en esta tesis han mejorado significativamente la precisión de la estimación de la  $T_s$ , con errores inferiores al kelvin. Los resultados estadísticos derivados de la validación metodológica de los muestreos realizados con IS MODIS y Landsat sugieren que el modelo de remuestreo basado en la diferencia de límites es el modelo que presentó la mejor performance de la  $T_s$  a nivel de subpíxel. El modelo  $T_s$ HARP y el  $T_s^*$  Dif. de límites mostraron resultados similares en la desagregación de datos térmicos a nivel de subpíxel; sin embargo, el modelo  $T_s^*$  Dif. de límites muestra un

comportamiento más estable en el remuestreo de IS de baja resolución (MODIS Terra) hacia imágenes de alta resolución espacial (Landsat TM).

La sensibilidad de los modelos depende de la proporción de suelo desnudo y de vegetación para cada píxel remuestreado. Esto último se observa en la performance de los modelos en IS MODIS, donde los errores estadísticos en términos del RMSE son menores en zonas con alto  $P_v$  (menores a 0,43 K) y mayores en zonas de baja  $P_v$  con baja humedad (del orden de 0,69 K). Además es importante indicar que los modelos que utilizan índices de estrés hídrico para la simulación de la  $T_s$  no demostraron ser más precisos que los modelos basados en el espacio NDVI -  $T_s$ . Por lo tanto, se deberían seguir otras líneas de investigación probando con otras variaciones metodológicas a efecto de perfeccionar los resultados obtenidos.

En imágenes Landsat TM el modelo de  $T_s^*$  Dif. de límites mostró mejor performance para los diferentes tipos de coberturas analizadas para los estadísticos  $R^2$ , RMSE y RMSE/ . Al evaluar el comportamiento en cultivo de maíz y en suelo desnudo húmedo los resultados indicaron que las clases presentaron un 90 y 85 % de performance y RMSE de 0,33 K y 0,54 K respectivamente. Los resultados indican que la humedad del suelo y el contenido de agua en las plantas es un parámetro de extrema importancia en la estimación de la  $T_s$  a alta resolución espacial y debe de ser tenido en cuenta al momento de modelar.

El modelo  $T_s^*$  Dif. de límites presenta una buena aptitud para los sistemas suelo agua planta analizados a diferente resolución espacial y además, mostró buenos resultados en comparación medidas realizadas *in situ* para un cultivo de soja y otro de trigo. Si se considera la escala de trabajo utilizada en la parcela de trigo sería recomendable realizar la validación del modelo  $T_s$  Dif. de límites en un área de mayor extensión a la utilizada en este trabajo para una adecuada valoración de los remuestreos MODIS (preferentemente mayor a 15000 ha).

Disponer diariamente de datos térmicos de alta o moderada resolución espacial (< 250 m) a partir del uso conjunto de información proveniente de diferentes misiones de satélite sería un paso significativo para el conocimiento de comportamiento de la  $T_s$  y condiciones de estrés hídrico en regiones agrícolas de gran heterogeneidad como la región pampeana sub-húmedo. Basado sobre la evidencia obtenida en este trabajo, el modelo de  $T_s^*$  Dif. de límites es recomendado para la obtención de mapas regionales de  $T_s$  a alta resolución espacio - temporal.

Si bien los resultados obtenidos en este trabajo son coincidentes con los observados por otros autores en otras regiones del mundo (EE.UU e India), constituye el primer antecedente en la región pampeana sub-húmeda.

### ***RECOMENDACIONES***

Los datos agregados de IS de baja resolución no siempre son representados de forma adecuada a nivel de subpíxel. Una inadecuada co-registración (errores mayores a 1 píxel) y remuestreo en escalonamiento no múltiplo (por ejemplo: remuestreo de imágenes Landsat TM de 120 m a tamaño de píxel MODIS de 250 m) conduce a incrementos en la incerteza de la agregación de los datos térmicos. Entonces, se sugiere que los modelos de remuestreo deben ser planteados en pasos escalonados (por ejemplo: 1 Km, 750 m, 500 m y 250 m para IS MODIS), a fin de evitar la pérdida de variabilidad y obtener un mejor resultado en la agregación de la  $T_s$ .

Como perspectiva futura se intentará implementar métodos de remuestreo utilizando datos térmicos del sensor NIRST (SAC-D), vuelos con UAV (aviones no tripulados) y datos diarios adquiridos por el sensor MODIS.

## **REFERENCIAS BIBLIOGRÁFICAS**

Agam, M.C., Kustas, W.P., Anderson, M., Li, F., Neale, C.M.U. (2007a). A vegetation index based technique for spatial sharpening of thermal imagery. *Remote Sensing of Environment* , 107, 545-558.

Agam, N., Kustas, W.P., Anderson, M.C., Li, F y Colaizzi, P.D. (2007). Utility of thermal sharpening over Texas high plains irrigated agricultural fields. *Journal of Geophysical Research* , 112. D19110, doi:10.1029/2007JD008407.

Agam, N., Kustas, W.P., Anderson, M.C., Li, F., Colaizzi, P.D. (2007b). Utility of thermal sharpening over Texas high plains irrigated agricultural fields. *Journal of Geophysical Research* , 112, D19110, doi:10.1029/2007JD08407.

Anderson, M.C., Norman, J.M., Mecikalski, J.R., Torn, R.D., Kustas, W.P., Basara, J.B. (2004). A multi-scale remote sensing model for disaggregating regional fluxes to micrometeorological scales. *. Journal of Hydrometeorology* , 5, 343-363.

Atitar, M., Sobrino, J.A., Jiménez, J.C., Oltra, R., Julien, Y., Sória, G., Ruescas, A., Hidalgo, V. (2008). Algoritmo de estimacion de la temperatura de la superficie terrestre con el MSG2: test y comparación con datos in situ y productos MODIS y LandSAF. *Revista de Teledetección* , ISBN: 1988-8740. Vol 30, pag:60-70.

Barnaby, C., Suomalainen, J., Pellikka, P. (2010). A comparison of methods for the retrieval surface reflectance factor for multitemporal SPOT HRV, HRVIR, and HRG multispectral satellite imagery. *Can. J. Remote Sensing* , Vol. 36. Nro. 4, pp. 397-411.

Benito,A. (2009). ESTIMACIÓN DE LA EMISIVIDAD ESPECTRAL CON DATOS TÉRMICOS. *Teledetección: Agua y desarrollo sostenible. XIII Congreso de la Asociación Española de Teledetección.* , Calatayud, pag: 525-528. Editores: Salomón Montesinos Aranda y Lara Fernández Fornos.

Basso, B., Cammarano, D., De Vita, P. (2004). Remotely sensed vegetation indices: theory and applications for crop management. *Risista Italiana di Agrometeorologia* , pag: 36-53.

Becker,F., Li, Z.L. (1995). Surface temperature and emissivity at different scales: definition,measurement and related problems. *Remote Sensing Reviews* , Vol 12, pag:225–253.

Bian, L., Butler, R., Quattrochi, D.A., Atkinson, P.M. (1999). Comparing effects of aggregation methods on statistical and spatial properties of simulated spatial data. *Photogrammetry and Remote Sensing.* , 65:73-84.

Broge, N. H., and 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* , Volumen 76, pag: 156-172.

Cai , J., Liu, Y., y Pereira, L.S. (2007). Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages. *Agricultural and Forest Meteorology* , 145, 22-35.

Camacho, F., Eberle, A., Lanjeri, S., Martínez, B., Lopez-Baeza, E. (s.f.). Diseño de un índice espectral optimizado para la estimación del contenido en agua de la vegetación con datos MODIS. *Teledetección: Agua y desarrollo sostenible. XIII Congreso de la Asociación Española de Teledetección.* , Calatayud, 23-26 de septiembre de 2009. pp. 449-452. Editores: Salomón Montesinos Aranda y Lara Fernández Fornos.

Carmona F., Girolimetto D., Ocampo D., Holzman M., Venturini V., Rivas R. (2010a). Validation of data from the SAC-D/Aquarius mission. Application to the knowledge of vegetation water stress. *3rd International Symposium on the Recent Advances in Quantitative Remote Sensing. Editor Global Change Unit.* , pp 178. V-2818-2010.

Carmona, F., Rivas, R., Caselles, V. (2010b). Estimación del parámetro alfa de Priestley-Taylor en condiciones de secano. *I Congreso Internacional de Hidrología de Llanuras, Azul, Buenos Aires.* , Aceptado.

Carmona, F., Rivas, R.,. (2011.). *Estimación de la evapotranspiración real mediante datos meteorológicos e imágenes de satélite.* Tandil, Buenos Aires, Argentina.: Editorial Martin, IDBN:978-987-543-443-1.

Carmona, F., Rivas, R., Thomas, L.P., Marino, B.M. (2011.). Caracterización espectral del estuario del Río Quesquén Grande por medio de imágenes Landsat. *Teledetección: Recientes aplicaciones en la Región Pampeana.* , Cap 1, Editores: Raúl Rivas, Facundo Carmona y Dora Ocampo. Editorial Martin.

- Carter, A.J., Ramsey, M.S. . (2009). ASTER- and field-based observations at Bezymianny Volcano: Focus on the 11 May 2007 pyroclastic flow deposit. *Remote Sensing of Environment* , Volumen 113, Pag: 2142-2151 .
- Ceccato, P., Flasse, S., and Gregoire, J.M. (2002.). Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. *Remote Sensing of Environment* , Vol 82, pag:198-207.
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemond, S., and Gregoire, J.M. (2001). Detecting vegetation water content using reflectance in the optical domain. *Remote Sensing of Environment* , Vol 77, pag:22–33.
- Ceccato, P.N., Gobron. (2002). Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1. Theoretical approach. *Remote Sensing of Environmet* , Vol 82, pag:188-197.
- Chan, L., Yan, G., Ren, H., Li, A. (2010). A modified vegetation index based algorithm for thermal imagery sharpening . *IGARRS-IEEE* , 978-1-4244-9566-5/10.
- Chander, G., Markham, B. . (2003). Revised Landsat-5 TM Radiometric Calibration Procedures and Postcalibration Dynamic Ranges. *IEEE Transactions on Geoscience and Remote Sensing* , Vol 41(11), pag:2674-2677.
- Chander, G., Markham, B.L., Barsi, J.A. (2007). Revised Landsat-5 Thematic Mapper Radiometric Calibration. . *IEEE Geoscience and Remote Sensing Letters* , Vol 4(3), pag:490-494.
- Chander, G., Markham, B.L., Helder, D.L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+ and EO-1 ALI sensors. *Remote Sensing of Environment* , Vol 103, pag:893-903.
- Chávez, P.S. (1989). An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment* , Vol.24, pag:459-479.
- Chávez, P.S. (1996). Image-based atmospheric correction- Revisited and improved. *Photogrammetric Engineering and Remote Sensing* , Vol 62(9), pag:1025-1036.
- Chubieco Salinero, E. (2008). *Teledetección Ambiental*. Barcelona (España): Tercera Edicion. Ariel S.A. ISBN: 978-84-344-8073-3.

Coll, C., Caselles, V. (1997). A Split-Window Algorithm for Land Surface Temperature from Advanced Very High Resolution Radiometer Data: Validation and Algorithm Comparison. . *Journal of Geophysical Research* , Vol. 102.97JDO0929.

Coll, C., Caselles, V. (1997). A Split-Window Algorithm for Land Surface Temperature from Advanced Very High Resolution Radiometer Data: Validation and Algorithm Comparison. *Journal of Geophysical Research* , Vol. 102, Nro.D14, pag:16,697-16,713, doi:10.1029/97JDO0929.

Coll, C., Caselles, V., Galve, J.M., Valor, E., Niclós, Raquel., Sanchez, J., Rivas, R. (2005). Ground measurements for the validation of land surface temperatures derived from AATSR and MODIS data. *Remote Sensing of Environment* , Vol 97, pag:288 – 300.

Danson, F.M., Bowyer, P. (2004). Estimating live fuel moisture content from remotely sensed reflectance. *Remote Sensing of Environment* , Vol 92, pag:309–321.

Dash, P., Gottsche, F., Olesen, S., Fisher, H. (2002). Land surface temperature and emissivity estimation from passive sensor data: theory and practice-current trends. *Int. J. Remote Sensing.* , Vol.23, Nro.13, 2563-2594.

Di Bella, C.M., Posse, G., Beget, M.E., Fischer, M.A., Mari, N., Veron, S. (2008). La teledetección como herramienta para la prevención, seguimiento y evaluación de incendios e inundaciones. *Ecosistemas* , 17(3):39-52.

Dingman, D.L. (2002). *Physical hydrology*. New Jersey: 2da. Edicion. Prentice-Hall.

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* , Vol 87, pag:111– 121. .

Foody, G.M. (2004). Spatial non-stationarity and scale-dependency in the relationship between species richness and environmental determinants for the sub-Saharan endemic avifauna. *Global Ecology & Biogeography* , Vol 13, pag: 315–320.

Galve, J.M., Coll, C., Casselles, V., Valor, E. (2008). An Atmospheric Radiosounding Database for Generating Land Surface Temperature Algorithms. *IEEE - Transactions on Geoscience and Remote Sensing.* , Vol. 46, Nro. 5.

Gao, B. C. (1996). NDWI a Normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment* , Vol 58, pag: 257– 266.

Gao, Z., Gao, W., Chang, N. (2011). Integrating temperature vegetation dryness index (TVDI) and regional water stress index (RWSI) for drought assessment with the aid of LANDSAT TM/ETM+images. *International Journal of Applied Earth Observation and Geoinformation* , Volumen 13, Pag: 495-503, ISSN: 15698432.

Ghulam, A., Qin, Q., Teyip, T., Li, Z. (2007). Modified perpendicular drought index (MPDI): a real-time drought monitoring method. *ISPRS Journal of Photogrammetry and Remote Sensing.* , Volumen 62, Pag: 150-164, ISSN: 09242716.

Gillespie, A.R. (1985). Lithologic mapping of silicate rock susing TIMS. *Proceedings TIMS Data User's Workshop (Pasadena, CA: Jet Propulsion Laboratory)* , JPLPub.86-38, pag:29-44.

Gillespie, A.R., Rokugawa, S., Matsunaga, T., Cothorn, J.S., Hook,S.J., Kahle,A.B. (1998). A temperature and emissivity separation algorithm for advanced spaceborne thermal emission and reflection radiometer (ASTER) images. *EEETransactionsonGeoscienceandRemoteSensing* , Vol 36, pag:1113–1126.

Girolimetto, D., Venturini, V., Rodriguez, L. (2007). Influencia de la resolucion espacial de la temperatura de superficie teledetectada en el contexto NDVI-Ts. *TELEDETECCION - Hacia un mejor entendimiento de lo dinámica global y regional* , ISBN: 978-987-543-126-3.

Girolimetto, D., Venturini, V., Rodríguez, L. (2007). *Influencia de la resolución espacial de la temperatura de superficie teledetectada en el contexto NDVI - To*. Santa Fe, Argentina.: Ed. Martin, ISBN: 978-987-543-126-3.

Girolimetto, D., Venturini, V., Rodriguez, L. (2007). Influencia de la resolucion espacial de la temperatura de superficie teledetectada en el contexto NDVI-Ts. *TELEDETECCION - Hacia un mejor entendimiento de lo dinámica global y regional* , ISBN: 978-987-543-126-3.

Gitelson, A. A., Kaufman, Y., and Merzlyak, M. (1996). Use of a green channel in remote sensing of global vegetation from eos-modis. *Remote Sensing of Environment* , Volumen 58, pag: 289-298.

Hong, S.H., Hendrickx, J.M.H. and Borchers, B. (2009). Up-scaling of SEBAL derived evapotranspiration maps from Landsat (30 m) to MODIS (250 m) scale . *Journal of Hydrology* , 370:122-138.

Houspanossian, J., Rivas R., Vazquez, P., Vives, L. (2008). *Evaluación de la respuesta de tre índices de estrés hídricos en vegetación de la región pampeana argentina*. Quito Ecuador. 8 al 12 de julio.: IX Congreso Latino Americano de Hidrología Subterránea y Expo Agua.

Houspanossian, J., Rivas, R., Vazquez, P. (2006). Relación entre la temperatura radiativa de la cubierta vegetal y la humedad del suelo en un cultivo de maíz. II Congreso Iberoamericano de Ambiente y Calidad de Vida. Facultad de ciencias Exactas y Naturales. ISBN 950-746-147-7. UNCa. Av. Belgrano 300. CP 4700. San Fernando del Valle de Catamarca. Argentina. Organizado por: Universidad Nacional de Catamarca (FACEN) y III CIACVI.

Huete, A., Didan, K., Miura, T. (2002). Overview of the radiometric and biophysical performance of the modis vegetation indices. *Remote Sensing of Environmet* , Volumen 83, pag: 195-213.

Inamdar, A.K, French, A. . (2009). Disaggregation of GOES land surface temperature using surface emissivity. *Geophysical Research Letters* , 36, L02408, doi: 10.1029/2008GL036544.

Inamdar, A.K., French, A. (2009.). Disaggregation of GOES land surface temperatures using surface emissivity. *Geophysical Research Letters* , Vol 36, L02408, doi:10.1029/2008GL036544.

Jeganathana,C., Hammb, N.A.S., Mukherjeec, S., Atkinsona, P.M., Rajud, P.L.M., Dadhwale, V.K. (2011). Evaluating a thermal image sharpening model over a mixed agricultural landscape in India. *International Journal of Applied Earth Observation and Geoinformation* , Vol 13, pag:178–191.

Jimenez Muñoz, J., and Sobrino, J. (2003). A generalized single-channel method for retrieving land surface temperature from remote sensing data. . *Journal of Geophysical Reserch* , Vol. 108 NO.D22, 4688, doi:10.1029/2003JD003480.

Jimenez Muñoz, J.C., Sobrino, J. (2009). Land surface temperature retrieval from METOP-AVHRR3 data using a split-window algorithm. *Unidad de Cambio Global, Laboratorio de Procesado de Imágenes, Universidad de Valencia*.

Jimenez-Muñoz, J., Sobrino J. (2003). A generalized single-channel method for retrieving land surface temperature from remote rensing data. *Journal of Geophysical Research. Global Change*

Unit, Department of Thermodynamics, Faculty of Physics, University of Valencia, Burjassot, Spain.  
, Vol 118, D22,4688:10.1029/2003JD003480.

Kaps, M., Lamberson, W. (2004). *Biostatistics for animal science*. Inglaterra: Editorial Cabi; ISBN:0851998208 .

Karnieli, A., Bayasgalan, M., Bayarjargal, Y., Agam, N., Khudulmur, S., Tucker, C.J. (2006). Comments on the use of the Vegetation Health Index over Mongolia. *International Journal of Remote Sensing* , Volumen 27, Pag: 2017-2024 .

Kim, G., Barrows, A.P. (2002). Downscaling of remotely sensed soil moisture with a modified fractal interpolation method using contraction mapping and ancillary data. *Remote Sensing of Environment* , Vol 83, pag:400–413.

Kufer, A.J., Farris, C.A. (2007 ). Incorporating spatial non-stationarity of regression coefficients into predictive vegetation models. *Landscape Ecology* , Vol 22, pag: 837–852.

Kustas, W.P., Li, F., Jackson, T.J., Prueger, J.H., MacPherson, J.I., Wolde, M. (2004). Effect of remote sensing pixel resolution on modeled energy flux variability of croplands in Iowa. *Remote Sensing of Environment* , 92, 535-547.

Kustas, W.P., Norman, J.M., Anderson, M.C., French, A.N. (2003). Estimating subpixel surface temperatures and energy fluxes from the vegetation index-radiometric temperature relationship. *Remote Sensing of Environment* , 85:429-440.

Kustas, W.P., Norman, J.M. (2000.). Evaluating the effects of subpixel heterogeneity on pixel average fluxes. *Remote Sensing of Environment* . , 74, 327–342.

Li, F., Jackson, T.J., Kustas, W.P., Schumugge, T.J., French, A.N., Cosh Rajat Bindlish, M.H. (2004). *Remote Sensing of Environment* , Vol. 92, pag:521-534.

Li, F., Kustas, W.P., Anderson, M.C., Prueger, J.H., Scott, R.L. (2008.). Effect of remote sensing pixel resolution on interpreting tower-based flux observations. *Remote Sensing of Environment* , 112, 337-349.

Liang, S. (1994). *Quantitative Remote Sensing of Land Surfaces*. A John Wiley & Sons.

- Liang, S., Fang, H., Chen, M., Shuey, C., Walthall, C., Daughtry, C., Morissette, J., Schaaf, C., Strahler, A. (2002). Validating MODIS land surface reflectance and albedo products: methods and preliminary results. *Remote Sensing of Environment*, Vol 83, pag:149–162.
- Liu, D., Pu, R. (2008). Downscaling thermal infrared radiance for sub-pixel land surface temperature retrieval. *Sensors* 8, pag:2695–2706.
- Mallick, K., Bhattacharya, B.K., Patel, N.K. (2009). Estimating volumetric surface moisture content for cropped soils using a soil wetness index based on surface temperature and NDVI. *Agricultural and Forest Meteorology*, Volumen 149, pag: 1327-1342.
- Merlin, O., Al Bitar, A., Walker, J.P., Kerr, Y. (2009). A sequential model for disaggregating near-surface soil moisture observations using multi-resolution thermal sensors. *Remote Sensing of Environment*, Vol 113, pag:2275–2284.
- Merlin, O., Walker, J.P., Chehbouni, A., Kerr, Y. (2008). Towards deterministic down-scaling of SMOS soil moisture using MODIS derived soil evaporative efficiency. *Remote Sensing of Environment*, Vol 112, pag:3935–3946.
- Miller, M., Porcasi, X., Sione, W., Scavuzzo, M. (2010). Utilización de datos satelitales para la generación de información vinculada a infección por *Triatoma infectans*. *Geografía y Sistemas de Información Geográfica (GEOSIG)*, ISSN: 1852-8031. Luján, Año 2, Nro.2, Sección artículos: I. pag:54-78.
- Moran, M.S., Rahman, A.F., Washburne, J.C., Kustas, W.P. (1996.). Combining the Penman-Monteith equation with measurements of surface temperature and reflectance to estimate evaporation rates of semiarid grassland. *Agricultural and Forest Meteorology*, 80:87-109.
- Moulin, S., Kergoat, L., Viovy, N., and Dedieu, G. (1997). Global-scale assessment of vegetation phenology using noaa/avhrr satellite measurements. *Journal of Climate*, Volumen 10, pag:1154-1170.
- Mukherjee, S. (2008.). *Multi-resolution technique for disaggregation of thermal image using vegetation index*. India: Thesis Master of Science. International Institute for Geoinformation Science and Earth Observation/Indian Institute of Remote Sensing, National Remote Sensing Agency (NRSA).

- Mukherjee, S. (2008). Multi-resolution technique for disgregation of thermal image using vegetation index. *International Institute for Geo-Information Science and Earth Observation Enchede (ITC) and Indian Institute of Remote Sensing (IIRS)* , Dehradun, India. .
- Myneni, R. B., Hall, F. G., Sellers, P., and Marshak, A. L. (1995). The interpretation of spectral vegetation indexes. *IEEE Transactions on Geoscience and Remote Sensing* , Volumen 33, pag: 481-486.
- Ocampo, D., Rivas, R., Carmona, F., Figueredo, H., Palazzani, L. (2011). *Estimación de rendimiento de trigo por ambientes a partir de datos del sensor Thematic Mapper*. Tandil, Buenos Aires, Argentina.: Editorial Martin. ISBN: 978-987-543-443-1.
- Ormeño, S. (2006). *Teledetección Fundamental*. Madrid, España.: 3ª edición. Cátedra de E.U, Universidad Politécnica Madrid.
- Parkinson, C.L., Ward, A., King, M. (eds). (2006). *Earth science reference handbook. A guide to NASAs earth science program and earth observing satellite missions*. Washinton, D,C., National Aeronautics and Space Administration.
- Prata, A., Caselles, V., Coll, C., Sobrino, J., Ottlé, C. (1995). Thermal remote sensing of land surface from satellites: current status and future prospects. *Remote Sensing Review* , Vol.12, pag:175-224.
- Prata, A.J. (1993). Land surface temperature derived form the advanced very high resolution radiometer and the along tranck scanning radiometer. *Theory J. Geophys. Res.* 98:16689-702.
- Purevdorj, T. S., Tateishi, R., Ishiyama, T., and Honda, Y. (1998). Relationships between percent vegetation cover and vegetation indices. *Int. J. Remote Sens* , pag: 3519-3535.
- R Development Core Team. (2010). *R: A Language and Environment for Statistical Computing*. Vienna, Austria: ISBN:3-900051-07-0 \_ <http://www.R-project.org/>.
- Raynolds, M., Comiso, J., Walker, D., Verbyla, D. (2008). Relationship between satellite-derived land surface temperature, artic vegetation types an NDVI. *Remote Sensing of Environment* , Vol 112, pag:1884-1894.

Rivas R.; Houspanossian J. (2006). Obtención de mapas de estrés hídrico a partir de datos captados por los sensores AVHRR y MODIS. . *Actas VIII Congreso de Asociación Latinoamericana de Hidrología Subterránea para el Desarrollo, Asunción del Paraguay* , 26-29 Septiembre.

Rivas, R., Caselles, V. (2004). A simplified equation to estimate spatial reference evaporation from remote sensing-based surface temperature and local meteorological data. *Remote Sensing of Environment* , Vol 93, pag: 68-76.

Rivas, R., Houspanossian, J. (2006). Obtención de mapas de estrés hídricos a partir de datos captados por los sensores AVHRR y MODIS. *VII Congreso Latinoamericano de Hidrología Subterránea* , Septiembre de 2006- Asunción, Paraguay.

Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., and Harlan, J. C. (1974). Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. *NASA/GSFC Type III Final Report* , Greenbelt, Maryland.

Rubio, E., Caselles, V., Coll, E., Valour, E., Sospredra F. (2003). Thermal-infrared emissivities of natural surfaces: improvements on the experimental set-up and new measurements. *Remote Sensing* , Vol. 24, Nro. 24.5379-5390.

Sánchez, J.M., Kustas, W.P., Caselles, V., Anderson, M.C. (2008). Modelling surface energy fluxes over maize using a two-source patch model and radiometric soil and canopy temperature observations. *Remote Sensing of Environment* , Vol 112, pag:1130–1143.

Sandholt, I., Rasmussen, K., Andersen, J. (2002). A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment* , Volumen 79, pag:213-224.

Santer, R., Carrere, V., Dubuisson, P., Roger, J.C. (1999). Atmospheric correction over land for MERIS. *International Journal of Remote Sensing* , Vol 20, pag:1819–1840.

Schädlich, S., Göttsche, F.-M., Olesen, F.S. (2001). Influence of land parameters and atmosphere on Meteosat brightness temperatures and generation of land surface temperature maps by temporally and spatially interpolating atmospheric correction. *Remote Sensing of Environment* , Vol. 75, pag: 39–46.

- Sobrino, J. (2000). *Teledeteccion*. Universidad de Valencia: Guada Impresores S.L - ISBN: 84-370-4220-8.
- Sobrino, J., Soria, L., and Jiménez., J. C. (2002). Land surface temperature and emissivity retrieval from remotr sensing data. *Recent Research Developments on Geophysics* , 4, pag:21-44.
- Sobrino, J., Soria, L., and Jiménez., J. C. (2009). Thermal remote sensing from airborne hyperspectral scanner data in the framework of the SPARC and SEN2FLEX projects: an overview. *Hydrology and Earth System Sciences.* , Vol 13, pag:2031-2037.
- Sobrino, J., Soria, L., Jiménez, J.C. (2002). Land surface temperature and emissivity retrieval from remote sensing data. *Recent Research Developments on Geophysics.* , Nro. 4, pag:21-44.
- Sobrino, J., Sorio, L., and Jiménez, J.C. (2009). Thermal remote sensing from airborne hyperspectral scanner data in the frame work of the SPARC and SEN2FLEX projects. *Hydrology and Earth System Sciences* , 13:2031-2037.
- Stockle, C. K. (2004). Evaluation of estimated weather data for calculating Panman-Monteith reference evapotranspiration. *Irrigation Science* , 23, 39-46.
- Sun, D., Kufatos, M. (2007). Note on the NDVI-LST relationship and the use of temperature-related. *Geophysical Research Letters* , Vol 34, L24406, doi:10.1029/2007GL031485.
- Teillet, P.M., Fedosejevs, G. (1995). On the dark target approach to atmospheric correction of remotely sensed data. *Canadian Journal of Remote Sensing* , Vol 21, pag:374-387.
- Thomas, A., Byrne, D., Weatherbee, R. (2002). Costal sea surface temperature temperature variability from Landsat infrared data. *Remote Sensing of Environment.* , 81, 262–272.
- Townshend, J.G.R., Justice, C.O. (1988.). International Journal of Remote Sensing. *Selecting the spatial resolution of satellite sensors required for global monitoring of land transformations.* , 9,187–236.
- Tucker, C. J., Holben, B. N., Elgin, J. H., and McMurtrey, J. E. (1980). Relationship of spectral data to grain yield variations. *Photogramm. Eng. Remote. Sens.* , Volumen 46, pag: 657- 666.
- Valor, E., Caselles, V. (1996). Mapping land surface emissivity from NDVI application to European, African and South America areas. . *Remote Sensing Environment* , 57:167-184.

- Valor, E., Caselles, V. (1996). Mapping land surface emissivity from NDVI: Application to European, African and South American areas. *Remote Sensing of Environment* , Vol 57, 167-184.
- Vaughan, R.G.a , Keszthelyi, L., Davies, A., Schneider, D., Jaworowski, C. (2010). Exploring the limits of identifying sub-pixel thermal features using ASTER TIR data. *Journal of Volcanology and Geothermal Research.* , Volumen 189, Pag: 225-237.
- Vazquez, P. (2008). *Comparación de índices de estrés a partir de información captada por sensores remotos en el espectro IRT*. Tandil: Tesis de Maestría, Carrera de Teledetección y SIG. Facultad de Agronomía. UNCPBA.
- Wainschenker, R. S., Massa, M. J., Tristán, P. M., ( 2008). *Procesamiento de imágenes Satelitales*. Facultad de Ciencias Exactas, Universidad Nacional del Centro de la Provincia Buenos Aires.: Curso de postgrado.
- Walthall, C., Dulaney, W., Anderson, M., Norman, J., Fang, H., and Liang, S. (2004). A comparison of empirical and neural network approaches for estimating corn and soybean leaf area index from Landsat ETM+ imagery. *Remote Sensing of Environment* , Volumen 92, pag: 465-472.
- Wan, Z. (1999). MODIS land surface temperature algorithm theoretical basis document. *Institute for Computational Earth System Science. University of California, Santa Barbara*.
- Wan, Z., Zhang, Y., Zang, Q., Li, Z. (2002). Variation of the land surface temperature products retrieved from MODIS Terra data. . *Remote Sensing of Enviroment* , 83:163-180.
- Wang, K., and Liang, S. (2009). Evaluation of ASTER and MODIS land surface temperature and emisivity products using longwave radiation observations at SURFRAD sites. *Remote Sensing of Environment* , 113:1556-1565.
- Wang, L., Qu, J.J. (2007). NMDI: a normalized multi-band drought index for monitoring soil and vegetation with satellite remote sensing. *Geophys. Res. Lett.* , Vol 34, p. L20405, doi:10.1029/2007GL031021.
- Weinzettel, P. y Usunoff, E. (2001). Determinación del flujo por macroporos en suelos argiudoles en la cuenca del arroyo Azul, Argentina. *Carad del Agua Subterránea Conferencia, España* , 1:255-26.

Weinzettel, P., Usunoff, E. (2011). Cálculo de la recarga mediante aplicación de la ecuación de Darcy en la zona no saturada. . *Las caras del agua subterránea, Serie hidrogeológica y aguas subterráneas* , Tomo I, pag:225-232.

Willmott, C.J. (1981). On the variation models. *Phys. Geog* , Vol 2, pag:184-194.

Yang, G., Pu, R., Zhao, C., Huang, W., Wang, J. (2011). Estimation of subpixel land surface temperature using an endmember index based technique: A case examination on ASTER and MODIS temperature products over a heterogeneous area. *Remote Sensing of Environment* , Vol 115, pag:1202–1219.

Yang, H., and Yang, Z. (2006). A modified land surface temperature split window retrieval algorithm and its applications over China. *Global and Planetary Change.* , Vol 52, pag:207-215.

Yao, Y., Liang, S., Qin, Q., Wang, K., Zhao, S. (2011). Monitoring global land surface drought based on a hybrid evapotranspiration model. *International Journal of Applied Earth Observation and Geoinformation.* , Volumen 13, Pag: 447-457, ISSN: 15698432.

Zurita-Milla, R., Kaiser, G., Clevers, J.G.P.W., Schneider, W., Schaepman, M.E. (2009). Downscaling time series of MERIS full resolution data to monitor vegetation seasonal dynamics. *Remote Sensing of Environment* , Vol 113, pag: 1874–1885.

## ANEXOS

**ANEXO I:** Rutina de modelos de regresión lineal y estadísticos en R Statistic.

### Cargar las ROI's con datos extraídos de ENVI

```
source('readEnviROI.r')
x<-readEnviROI('suelo2.txt')
```

### Modelos de Regresión Lineal Límite Seco

```
plot(x[[1]][,1],x[[1]][,2],pch=1,xlim=c(0,1), ylim = range(280,310),font=8,col='orange',
bg='orange', cex=1, font.lab=8,xlab='NDVI Landsat 5 TM 120 mtrs',ylab='Ts Landsat 5 TM (K)
120 mtrs')
regress<-lsfit(x[[1]][,1],x[[1]][,2])
ls.print(regress)
abline(lsfit(x[[1]][,1],x[[1]][,2]), col=4, lty=1, lwd=2)
summary(regress)
savefont<-par(font=8)
legend("bottomleft", c("Y=-6.5X+294", "R²= 0.90", "Nro:7262"),lty=c(1,0,0),col=c(4,0,0),lwd=2)
```

### Modelos de Regresión Cuadrática Límite Húmedo

```
A<-x[[1]][,1]*x[[1]][,1]
lm.x<-lm(x[[1]][,2]~x[[1]][,1]+A)
plot(x[[1]][,2]~x[[1]][,1],font=8,font.lab=8,xlab='NDVI',ylab='Ts(K)',col='5')
print(lm.x$coef)
summary(lm.x)
savefont<-par(font=8)
legend("bottomleft", c("Y=-24.88X+15.77X+305.37", "R²= 0.98", "Nro:281"))
length(x[[1]][,1])
NDVI<-x[[1]][,1]
Ts<-x[[1]][,2]
quadratic.lm <- lm(Ts ~ poly(NDVI, 2))
Xsort <- sort(NDVI)
plot(NDVI, Ts,xlim=c(0,1),ylim=c(280,310),font=8, pch=1,col='orange', bg='orange', cex=1,
font.lab=8, ylab='Ts Landsat 5 TM (K) 120 metros', xlab='NDVI Landsat 5 TM 120 metros')
lines(Xsort, predict(quadratic.lm, list(NDVI=Xsort)), col=4, lty=1, lwd=2)
savefont<-par(font=8)
legend("bottomleft", c("Y=-
16.6X²+9X+305", "R²=0.87", "Nro:201"),lty=c(1,0,0),col=c(4,0,0),lwd=2)
summary(quadratic.lm)
print(quadratic.lm$coef)
length(x[[1]][,1])
```

### Modelos de Regresión Lineal

```
plot(x[[1]][,1],x[[1]][,2],pch=1,col=2,font=8,xlim=c(285,305), ylim
=c(285,305),font.lab=8,xlab='TsLandsat 5 TM (30 m)',ylab='Ts*HARP (30
m)',font.main=8,main='Suelo Desnudo')
regress<-lsfit(x[[1]][,1],x[[1]][,2])
ls.print(regress)
abline(lsfit(x[[1]][,1],x[[1]][,2]),lty=5,col=4,lwd=2)
savefont<-par(font=8)
legend("bottomright", c("Y=0.99X+2.55","R2= 0.69","Error
Típico:0.89","Nro:1103"),lty=c(5,0,0,0),col=c(4,0,0,0),lwd=2)
```

### Boxplots

```
par(font.lab=8)
par(font.axis=8)
boxplot(x[[1]][,1],x[[1]][,2],x[[1]][,3],x[[1]][,4],x[[1]][,5],x[[1]][,6],x[[1]][,8],horizontal= TRUE,
col=c(4,2,3,1,5,8,'orange'), notch=TRUE,xlab='Temperaturas (K)',ylab='Métodos de Remuestreo de
Datos Térmicos Landsat 5 TM (30 m)',
names=c('Ts','TsHarp','FCLS','FC_dif','SWI','NDII','GVMII'))
```

### Estadísticos

```
length(x[[1]][,1])
summary(x[[1]][,1])
sd(x[[1]][,1])

Rango1<-max(x[[1]][,1])-min(x[[1]][,1])
print(Rango1)

CV<-sd(x[[1]][,1])/mean(x[[1]][,1])*100
print(CV)

RMSE1<-sqrt(sum((x[[1]][,2]-x[[1]][,1])^2)/length(x[[1]][,1]))
print(RMSE1)

RE1<- (RMSE1/x[[1]][,1])
summary(RE1)

ME<-sum(x[[1]][,2]-x[[1]][,1])/length(x[[1]][,1])
print(ME)

skewness=function(x) {
m3=mean((x-mean(x))^3)
skew=m3/(sd(x)^3)
skew}
```

```
skewness(x[[1]][,1])
```

```
kurtosis=function(x) {  
m4=mean((x-mean(x))^4)  
kurt=m4/(sd(x)^4)-3  
kurt}  
kurtosis(x[[1]][,1])
```

```
d<-(1-((sum((x[[1]][,2]-x[[1]][,1])^2))/(sum((abs(x[[1]][,1]-mean(x[[1]][,2]))+abs(x[[1]][,1]-  
mean(x[[1]][,2]))^2))))))  
print(d)
```

```
a<-(sqrt(sum((x[[1]][,2]-x[[1]][,1])^2)/length(x[[1]][,1])))/sd(x[[1]][,2])  
print(a)
```

### Test de Normalidad Kolmogorov-Smirnof

```
ks.test((x[[1]][,1]),"pnorm",mean=mean(x[[1]][,1]),sd=sqrt(var(x[[1]][,1])))
```

### Test de Normalidad Chi Cuadrado

```
chisq.test(hist((x[[1]][,1]-  
mean(x[[1]][,1]))/sd(x[[1]][,1]),freq=FALSE,ann=FALSE,breaks=100,col=4,font=8,)$count)  
curve(dnorm, col=1,add=TRUE, lwd=2)  
title (main = NULL, sub = NULL, xlab = 'Ts Landsat(30 m)', ylab = 'Frecuencias Normalizadas',  
font.lab=8)
```

### Análisis de Residuos

```
lm.x <-lm(x[[1]][,1]~x[[1]][,2])  
opar <- par(mfrow = c(2,2), oma = c(0, 0, 1.1, 0))  
savefont<-par(font=8)  
plot(lm.x, las = 1,font=8,font.lab="8")  
par(opar)
```

**ANEXO II:** Parámetros de calibración Landsat TM.

**Tabla 1.** Coeficientes de ganancia y pérdida de sensor TM (*Chander et. al., 2007*).

Sensor TM	Bandas	Ganancia ( $G_\lambda$ )	Pérdida ( $B_\lambda$ )
	1	0,762824	-1,52
	2	1,442510	-2,84
	3	1,03980	-1,17
	4	0,872588	-1,51
	5	0,119882	-0,37
	6	0,055158	1,2378
	7	0,065294	-0,15

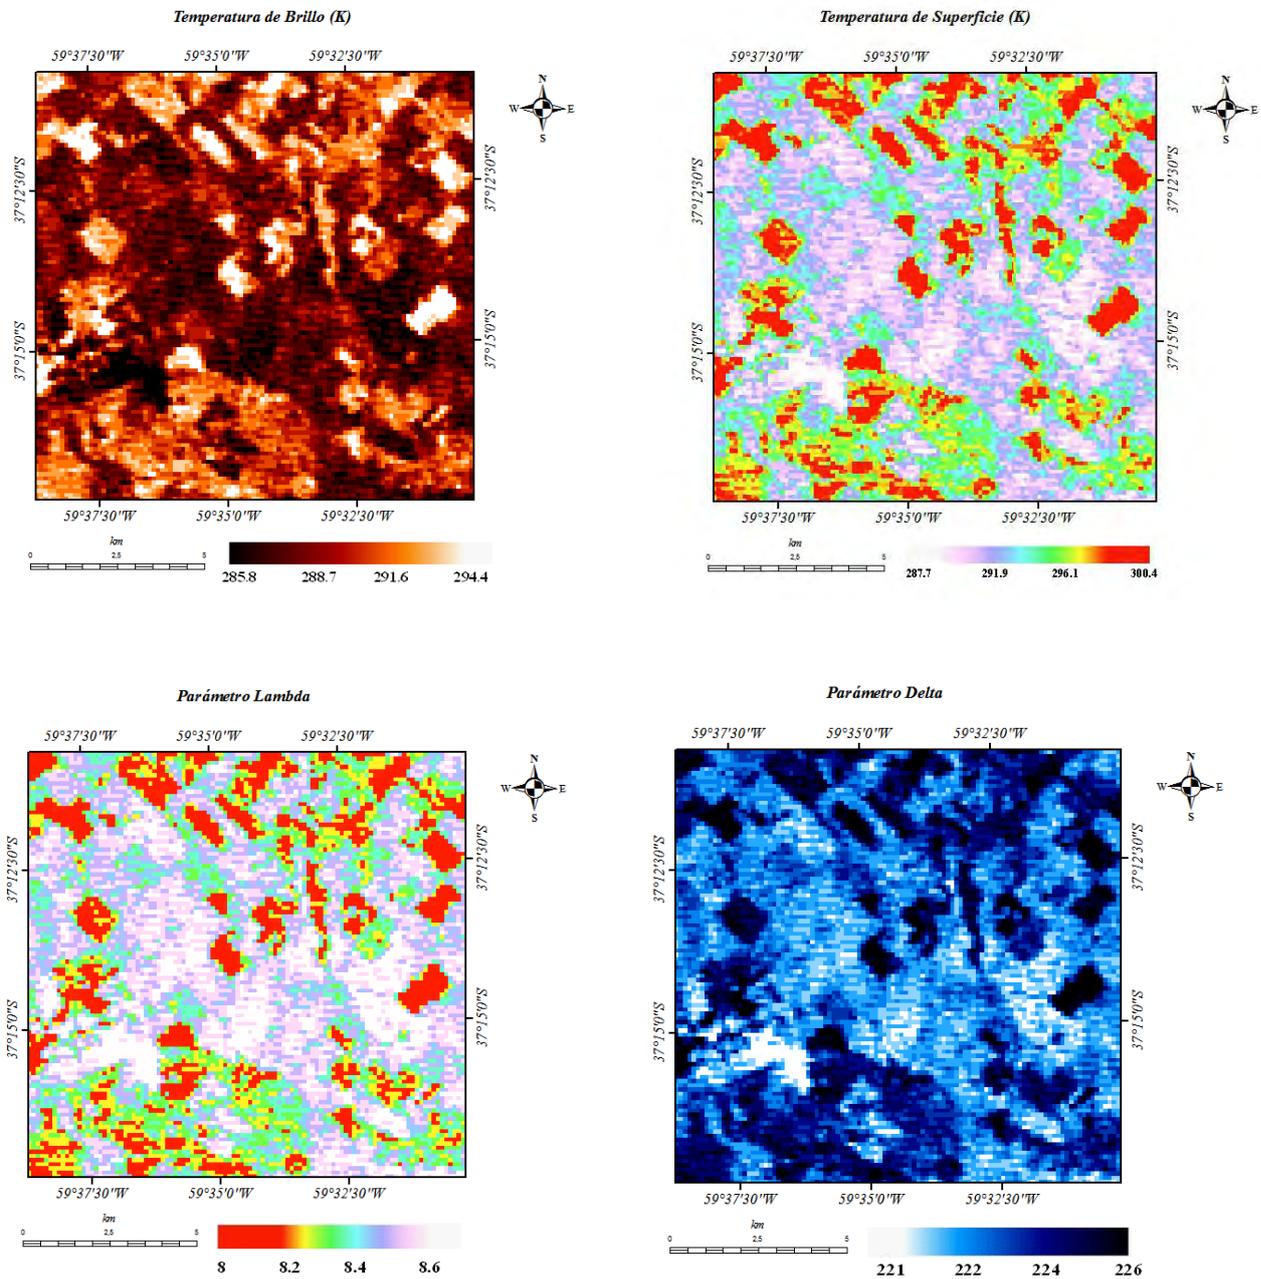
**Tabla 2.** Constantes de irradiancia solar espectral exoatmosférica (*USGS, 2007 y 2008*).

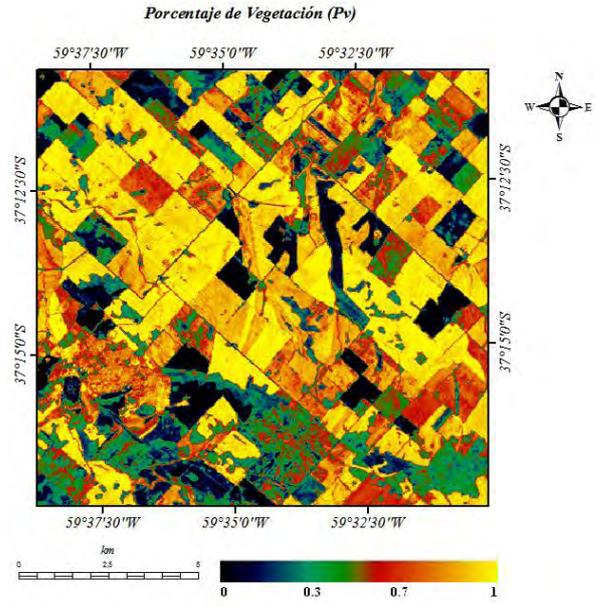
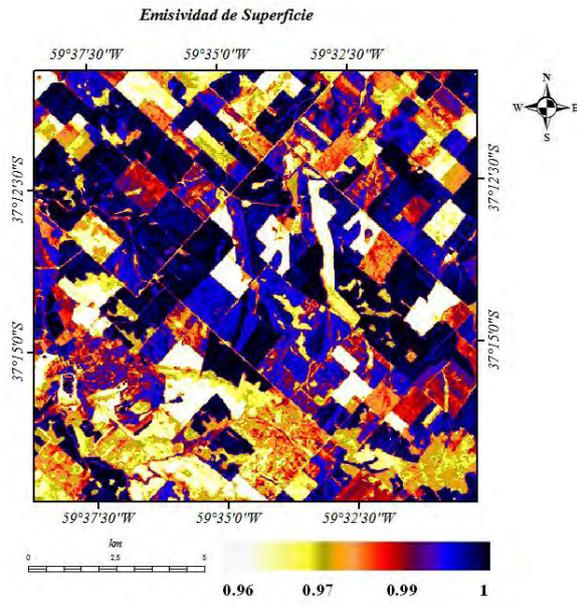
Sensor TM	Bandas	$E_{\lambda 0}$ ( $\text{W m}^{-2} \mu\text{m}^{-1}$ )
	1	1957,00
	2	1826,00
	3	1554,00
	4	1036,00
	5	215,00
	7	80,67

**Tabla 3.** Longitud de onda efectiva para la región VIS e IRC sensor TM.

Sensor TM	Bandas	$\lambda_m$ ( $\mu\text{m}$ )
	1 (azul)	0,485
	2 (verde)	0,560
	3 (rojo)	0,660
4 (IRC)	0,80	

**ANEXO III:** Mapas de secuencia metodológica para la estimación de la  $T_s$  para la imagen Landsat 5 TM adquirida el 23-02-2010. Datum WGS - 84, Sistema de proyección cartográfica UTM zona 21 S.





#### *ANEXO IV:* Rutina de agregación de píxeles en lenguaje IDL.

```
function ValorCentral, M, Xini, Xfin, Yini, Yfin

    return, M[Xini+round((Xfin-Xini)/2),Xini+round((Yfin-Yini)/2)]

end

function ValorPromedio, M, Xini, Xfin, Yini, Yfin

    return, mean(M[Xini:Xfin, Yini:Yfin])

end

function ValorMedio, M, Xini, Xfin, Yini, Yfin

    return, median(M[Xini:Xfin, Yini:Yfin])

end

function DesvioEstandar, M, Xini, Xfin, Yini, Yfin

    return, STDDEV(M[Xini:Xfin, Yini:Yfin])

end

function resample, M1, R1, R2, Tipo

    rel= round(R2/R1)

    sizem2 = size(M1, /dimension)/rel

    M2 = fltarr(sizem2)

    for i= 0,sizem2[0]-1 DO BEGIN

        for j= 0,sizem2[1]-1 DO BEGIN

            M2[i,j]= call_function(tipo, M1, i*rel, (i+1)*rel-1, j*rel, (j+1)*rel-
1)

        endfor

    endfor

    return, M2
```

**end**

Definiciones

```
PATH = 'C:\Users\Martin\Desktop\'
```

```
archivoIn = PATH+'Landsat_GVMI(960x960pixeles)_30mtrs'
```

```
archivoOut = PATH+'Landsat_GVMI(120m).img'
```

```
R2 = 120
```

```
envi, /restore_base_save_files
```

```
envi_init, /batch_mode
```

```
FORWARD_FUNCTION envi_select, ENVI_GET_DATA,envi_file_query, envi_get_map_info
```

```
ENVI_OPEN_FILE, archivoIn, r_fid=fid
```

```
ENVI_FILE_QUERY, fid, ns=ns, nl=nl
```

```
dims = [-1, 0, ns-1, 0, nl-1]
```

```
M1 = ENVI_GET_DATA(fid=fid, dims=dims, pos=0)
```

```
map_info = envi_get_map_info(fid=fid)
```

```
R1 = map_info.ps[0] ; Esto es posible si tiene la misma resolución en metros horizontal y vertical.
```

```
M2 = resample(M1,R1,R2, 'ValorPromedio')
```

```
pos=[1,2]
```

Actualizo el tamaño del pixel de la imagen original a la imagen de salida

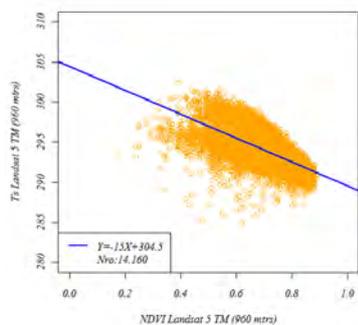
```
map_info.ps = [R2, R2]
```

```
ENVI_WRITE_ENVI_FILE, M2, out_name=archivoOut, map_info=map_info
```

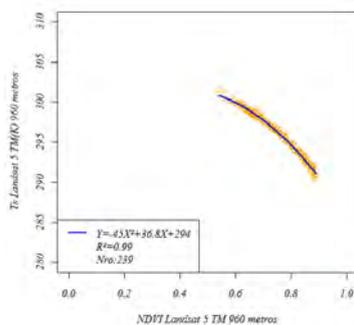
END

**ANEXO V:** Modelos de regresión lineal y cuadrática para identificar los límites a distintas resoluciones de la imagen Landsat 5 TM, fecha de adquisición 23/02/2010.

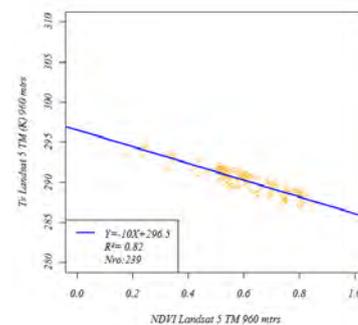
Resolución espacial a 960 m.



*Límite Central*

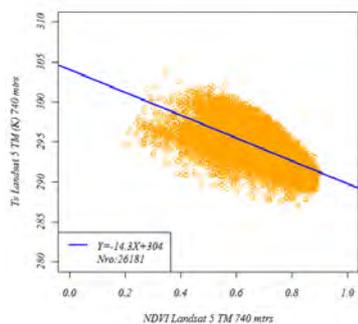


*Límite Seco*

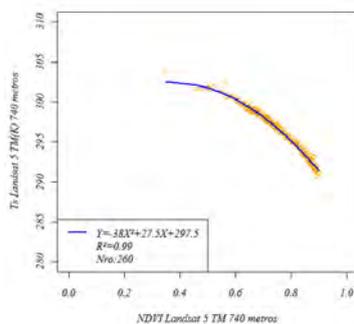


*Límite Húmedo*

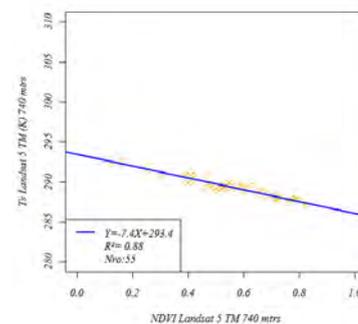
Resolución espacial a 720 m.



*Límite Central*

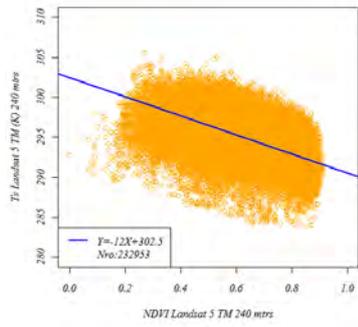


*Límite Seco*

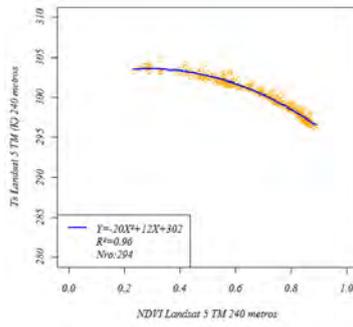


*Límite Húmedo*

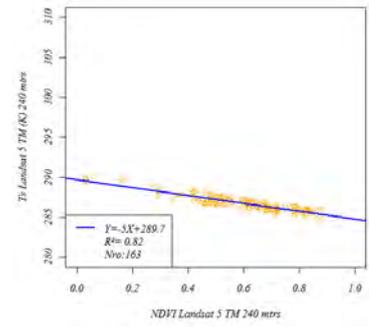
Resolución espacial a 240 m.



*Limite Central*

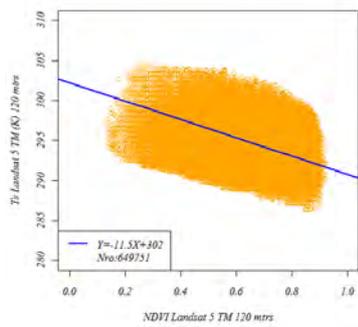


*Limite Seco*

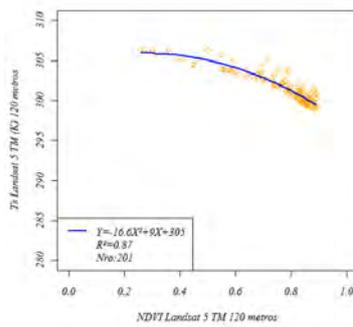


*Limite Húmedo*

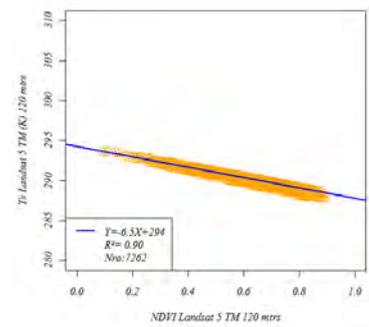
Resolución especial a 120 m.



*Limite Central*

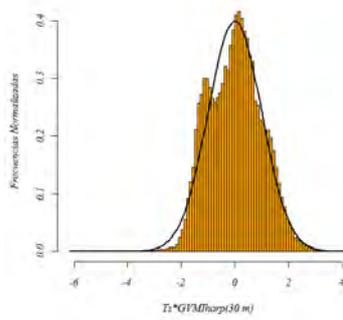
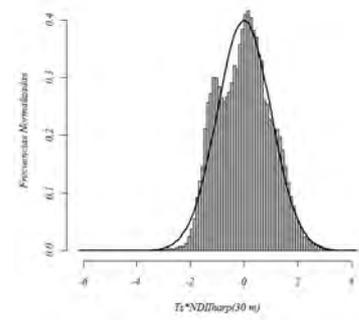
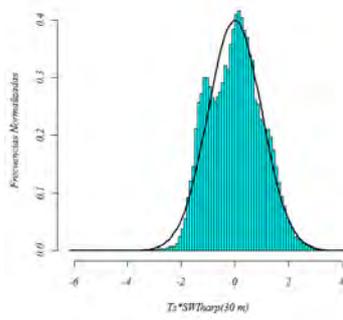
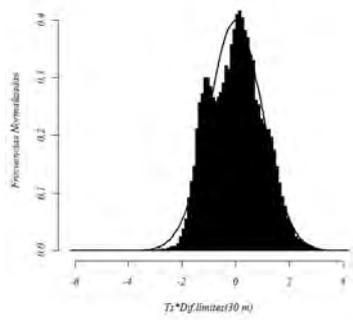
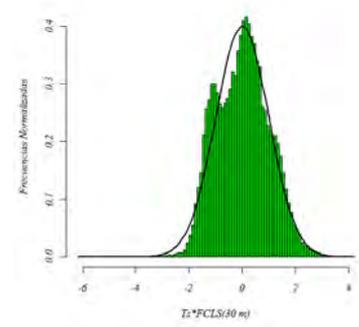
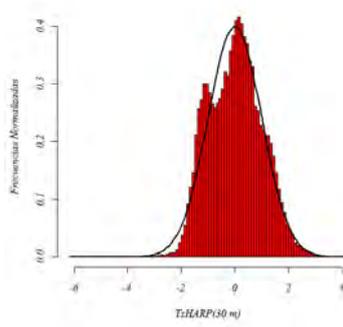
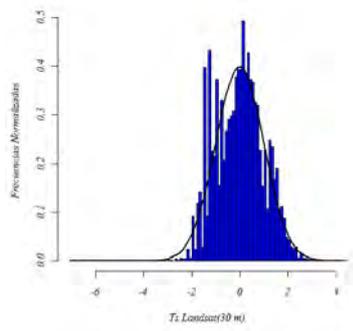


*Limite Seco*



*Limite Húmedo*

**ANEXO VI:** Histogramas de frecuencias de muestra de datos Landsat TM de 57.481 píxeles.



**ANEXO VII:** Mapas de secuencia metodológica para la estimación de la  $T_s$  en imagen MODIS Terra adquirida el 23-02-2010. Datum WGS-84, Sistema de proyección cartográfica UTM zona 21 S.

