

---

# USO DE SENSORES REMOTOS PARA LA PREDICCIÓN DE CASOS DE MALARIA EN EL DEPARTAMENTO ORÁN, SALTA, ARGENTINA

---

Por Lic. Ana Carolina Cuéllar

Presentado ante la Facultad de Matemática, Astronomía y Física  
y el Instituto de Altos Estudios Espaciales Mario Gulich  
como parte de los requerimientos para la obtención del grado de

MAGISTER EN APLICACIONES ESPACIALES DE ALERTA Y  
RESPUESTA TEMPRANA A EMERGENCIAS

UNIVERSIDAD NACIONAL DE CORDOBA

Julio, 2014

©IG - CONAE/UNC 2014

© FaMAF - UNC 2014

Directora: Dra. María Julia Dantur Juri  
CONICET-Instituto Superior de Entomología, FCN e IML- UNT  
Co-director: Dr. Camilo Rotela  
Instituto de Altos Estudios Espaciales "Mario Gulich" –UNC- CONAE



Uso de sensores remotos para la predicción de casos de malaria en el departamento Orán, Salta, Argentina por Ana Carolina Cuéllar se distribuye bajo una [Licencia Creative Commons Atribución-NoComercial-CompartirIgual 2.5 Argentina](https://creativecommons.org/licenses/by-nc-sa/2.5/arg/).

## CONTENIDO

---

<b>Índice de Figuras.....</b>	<b>4</b>
<b>Agradecimientos.....</b>	<b>7</b>
<b>Resumen.....</b>	<b>8</b>
<b>Abstract .....</b>	<b>9</b>
<b>Capítulo 1: Introducción, objetivos y área de estudio.....</b>	<b>10</b>
1.1 Introducción.....	10
1.1.1 La Malaria, distribución y situación actual.....	10
1.1.2 Los vectores de la Malaria .....	14
1.1.3 Epidemiología Panorámica .....	16
1.1.4 Sistemas de alerta temprana (para prevención de la Malaria) .....	18
1.1.5 Trabajos en Argentina con Sensores Remotos para la predicción de epidemias .....	19
1.2 Objetivos .....	20
1.3 Área de Estudio .....	21
<b>Capítulo 2: Fluctuación de casos de malaria en San Ramón de la Nueva Orán.....</b>	<b>24</b>
2.1 Introducción.....	24
2.2 Materiales y Métodos.....	25
2.2.1 Obtención de datos epidemiológicos .....	25
2.2.2 Fluctuación de casos en San Ramón de Orán .....	26
2.2.3 Análisis descriptivo de los casos de Malaria durante el período 1986-2005.....	28
<b>Capítulo 3: Obtención de series temporales a partir de imágenes satelitales.....</b>	<b>32</b>
3.1 Introducción.....	32
3.1.1 Características de las Imágenes Landsat.....	32
3.2 Materiales y Métodos.....	35
3.2.1 Selección de las imágenes Landsat.....	35
3.2.2 Pre procesamiento .....	36
3.2.2.1. Calibración .....	36
3.2.2.1.1 Cálculo de la radiancia .....	37
3.2.2.1.2 Cálculo de la reflectancia.....	40
3.2.2.1.3 Cálculo de la temperatura de brillo.....	41
3.2.2.2 Metodología para la calibración de las imágenes Landsat.....	42
3.2.2.2.1 Resultados de la calibración. ....	44
3.2.2.2.2 Conclusiones de la calibración.....	45

3.2.2.3 Georreferenciación.....	46
3.2.3 Índices normalizados de vegetación y agua.....	46
3.2.3.1 Índice normalizado de vegetación: NDVI .....	47
3.2.3.2 Índice normalizado de agua: NDWI .....	48
3.2.4. Metodología para la generación de series temporales de NDVI, NDWI y LST .....	50
<b>Capítulo 4: Modelos de series temporales ARIMA.....</b>	<b>54</b>
4.1 Introducción.....	54
4.1.1 Modelos ARIMA .....	54
4.1.2 Modelos ARIMA multivariantes: Función de transferencia .....	57
4.2 Materiales y Métodos.....	58
4.2.1 Ajuste del modelo .....	60
4.3 Resultados.....	60
<b>Capítulo 5: Influencia de las variables ambientales sobre los casos de malaria.....</b>	<b>63</b>
5.1 Materiales y métodos.....	63
5.2 Resultados.....	67
<b>Capítulo 6: Discusión y Conclusiones .....</b>	<b>71</b>
6.1 discusión .....	71
6.2 Conclusiones .....	81
<b>Referencias bibliográficas .....</b>	<b>82</b>
<b>Anexos.....</b>	<b>90</b>

## ÍNDICE DE FIGURAS

---

Figura 1. Distribución geográfica de la Malaria en el mundo (extraído de CDC, Center for Disease Control and Prevention, 2014).....	11
Figura 2. Áreas maláricas de Argentina en 2011 (extraído de Malaria Atlas Project, map, 2014) .....	13
Figura 3. Números de casos reportados de enfermos de Malaria para la Argentina desde 1990 hasta 2011 (extraído de World Health Organization, 2012).....	14
Figura 4. Distribución geográfica de algunas especies del género Anopheles en América (extraído de Kiszewski et al. 2004).....	15
Figura 5. Distribución geográfica de algunas especies de anofelinos en la Argentina (extraído de Augier, 2005). .....	16
Figura 6. Ubicación del área de estudio en el departamento Orán, provincia de Salta...	22
Figura 7. Fluctuación temporal de casos autóctonos/introductos de Malaria reportados en San Ramón de la Nueva Orán, provincia de Salta.....	27
Figura 8. Media de los casos de Malaria por mes desde 1986 hasta 2005 en San Ramón de la Nueva Orán, Salta. ....	28
Figura 9. Casos de Malaria de acuerdo al sexo (Masculino y Femenino) reportados anualmente para el período 1986-2005. ....	29
Figura 10. Casos de enfermos de Malaria divididos en grupos etarios para el periodo 1986-2005. ....	30
Figura 11. Frecuencia de casos de enfermos de Malaria de acuerdo a la ocupación durante el periodo 1986-2005.....	31
Figura 12. Misiones Landsat en el tiempo.....	33
Figura 13. Área de estudio (rectángulo rojo) en dos escenas de pasadas contiguas del satélite. Path 231 (escena de la izquierda) y path 230 (escena de la derecha).....	36
Figura 14. Relación entre los ND y la radiancia para la banda 3 (rojo) de los sensores TM (Landsat 5) y ETM+ (Landsat 7).....	37
Figura 15. Pasos de procesamiento de las imágenes satelitales para la obtención de las series temporales. ....	50
Figura 16. El recuadro amarillo muestra el área de interés (ROI) del cual se extrajeron .....	51
Figura 17. Esquema de las variables (media, valor mínimo, valor máximo y varianza)	

obtenidas de cada serie temporal (NDVI, NDWI, LST). .....	52
<b>Figura 18. Fluctuación temporal del NDVI medio para San Ramón de la Nueva Orán. El mes 0 corresponde a enero de 1986 y el mes 240 a diciembre de 2005. ....</b>	<b>53</b>
<b>Figura 19. Representación esquemática de la Función de Transferencia con dos inputs (predictor 1 y predictor 2). ....</b>	<b>57</b>
<b>Figura 20. Ajuste del modelo ARIMA (0,0,1)(0,0,0) y predicción para los casos de Malaria en San Ramón de la Nueva Orán, desde 1986 a 2000. ....</b>	<b>62</b>
<b>Figura 21. Fluctuación de casos de Malaria, NDVI media, NDWI media y LST media (para ajustar la escala se consideró a NDVImed y NDWImed multiplicada por 10). ....</b>	<b>65</b>
<b>Figura 22. Relación entre casos de Malaria y la variabilidad del NDVI medio y del LST medio. ....</b>	<b>68</b>
<b>Figura 23. Relación entre casos de Malaria y la variabilidad del NDVI medio y del LST medio. ....</b>	<b>70</b>

## ÍNDICE DE TABLAS

---

<b>Tabla 1. Rango espectral, parámetros de calibración e irradiancia solar exoatmosférica media (ESUN) del sensor TM.....</b>	<b>39</b>
<b>Tabla 2. Rango espectral, rangos de post-calibración e irradiancia solar exoatmosférica media (ESUN) del sensor ETM+.....</b>	<b>40</b>
<b>Tabla 3: Constantes de calibración de la banda térmica de los sensores TM y ETM+.....</b>	<b>42</b>
<b>Tabla 4: Valores de reflectancia de un pixel de la imagen Landsat 7 ETM de la calibrada usando las tres metodologías. ....</b>	<b>45</b>
<b>Tabla 5. Modelo ARIMA propuesto por el Modelador Experto.....</b>	<b>60</b>
<b>Tabla 6. Detalles de los parámetros del modelo propuesto por Modelador Experto.....</b>	<b>61</b>
<b>Tabla 7. Estimadores de la TF propuestos por el Modelador Experto.....</b>	<b>61</b>
<b>Tabla 8. Análisis de correlación entre las variables ambientales NDVI, NDWI y LST.....</b>	<b>64</b>
<b>Tabla 9. Estimadores del Modelo A.....</b>	<b>67</b>
<b>Tabla 10. Estimadores del Modelo B.....</b>	<b>69</b>

## AGRADECIMIENTOS

---

Esta humilde tesis está dedicada a mis compañeros de maestría (la cohorte 2011!) quienes, desde el principio, se volvieron mis amigos y con el correr de los meses, mis hermanos de corazón. La maestría no hubiese sido lo mismo sin todos Ustedes: Ferchus, Lilí, Fani, Laura, Gonza, Ariel, Manu, Andrés, Juan, Erith, Eli, Nazarena, y Carlos. Muchas gracias a todos ustedes por estar ahí siempre animándome... o simplemente por estar! LOS QUIERO MUCHACHOS! Sin duda, la mejor camada por lejos.

A María Julia Dantur Juri, por todo su apoyo desde hace muchos años.

A Camilo Rotela, por haber aceptado Co-dirigir esta tesis y por la buena onda de todos los días.

A Marcelo Scavuzzo, Mario Lamfri y Ximena Porcasi por todo su apoyo y consejos durante el paso por la Maestría y toda la gente del Instituto Gulich que de alguna forma, siempre ha estado ahí para ayudarme cuando necesite: Sofía, Nani, Carlos, Gastón, Seba, Martín, Marta, y a los chicos de la cohorte 2012.

A Diego Pons, por la ayuda brindada y por soportar todas las consultas técnicas.

A Mirta Santana y Oscar Bustos, por sus aportes en estadística.

A Giovanni Laneve, por la paciencia y el conocimiento compartido. A Pablo Marzialetti y a Roberto de Bonis, por haber hecho que mi estadía en Italia sea espectacular.

A mis amigos de Tucumán en especial a Ale, Flor, Claudia, Ana Nina y sobre todo a Romi Díaz Gómez, que siempre, a pesar de la distancia estuvieron allí.

Y a mi familia: hermanos, sobrinos y en especial a mis padres Estela y Juan, que desde SIEMPRE supieron apoyarme en todo lo que hago y me dieron ánimo cuando lo necesité y que sin ellos, no estaría hoy donde estoy.

A todos ustedes...MUCHAS GRACIAS!

## RESUMEN

---

La malaria es una enfermedad parasitaria que afecta a millones de personas en el mundo. Los mosquitos del género *Anopheles* han sido incriminados en su transmisión, existiendo reportes para la Argentina, de conocidas especies vectores también en América. El presente trabajo estuvo enfocado al uso de sensores remotos para la predicción de casos de Malaria en el extremo noroeste de Argentina. El estudio fue llevado a cabo en la ciudad de San Ramón de la Nueva Orán, donde fueron reportados casos de la enfermedad, desde 1986 hasta 2005. Se analizó la relación existente entre los casos de Malaria reportados y las variables ambientales/climáticas (Índice Normalizado de Vegetación (NDVI), Índice Normalizado de Agua (NDWI) y Temperatura de Superficie (LST)) obtenidas de imágenes satelitales Landsat 5 y 7, mediante análisis de regresión multinivel de Poisson. Se observó una fluctuación estacional de los casos de Malaria, con una mayor cantidad de enfermos reportada para los meses de verano. Se generó un modelo de series temporales ARIMA, que incluyó a las variables ambientales, y pudo pronosticar los casos de Malaria ocurridos durante el año 2000. A su vez, la relación entre los casos de Malaria y los factores ambientales/climáticos mostró mediante el uso de la Razón de la Tasa de Incidencia (IRR), que los casos de Malaria estuvieron asociados a un aumento en la LST media así como así también a una disminución del NDVI. Se espera que este trabajo pueda ser utilizado como base para el desarrollo de futuras acciones de prevención y control por parte de las autoridades en salud.



## ABSTRACT

---

Malaria is a parasitic disease that affects millions of people in the world. Mosquitoes of the *Anopheles* genus have been incriminated in the transmission of the disease. In Argentina, there are reports of vector species also known in America. This research was focused on the use of remote sensing for the prediction of malaria cases in the northwest of Argentina. This study was carried out using reported cases of the disease from San Ramón de la Nueva Orán city, from 1986 until 2005. The relation between Malaria cases and environmental variables (such as Normalized Difference Vegetation Index (NDVI), Normalized Difference Water Index (NDWI) and Land Surface Temperature (LST)) obtained from satellite imagery, using multilevel Poisson regression analysis, were analyzed. It was noted a seasonal fluctuation in the number of cases of malaria, with a greater number of patients reported for summer months. An ARIMA time series model, which included the environmental variables, was developed and it was possible to predict the number of cases of malaria occurred during the year 2000. At the same time, the relation between malaria cases and environmental factors showed through the use of reason in the incidence rate (IRR), that malaria cases were associated with an increase in the LST as well as well as a decrease of the NDVI. This work can be used as the basis for future prevention and control actions by Health Authorities.

---

# CAPÍTULO 1: INTRODUCCIÓN, OBJETIVOS Y ÁREA DE ESTUDIO

---

---

## 1.1 INTRODUCCIÓN

---

---

### 1.1.1 LA MALARIA, DISTRIBUCIÓN Y SITUACIÓN ACTUAL

---

La Malaria o Paludismo es una enfermedad parasitaria producida por protozoos del género *Plasmodium* y transmitida por la picadura de mosquitos hembra del género *Anopheles*. Son cinco las especies del género *Plasmodium* que producen la enfermedad en humanos: *Plasmodium vivax*, *Plasmodium falciparum*, *Plasmodium malariae*, *Plasmodium ovale* y *Plasmodium knowlesi* (Vargas Herrera, 2003; Bronner et al., 2009; World Health Organization, 2013). A comienzos del siglo 20 se reportó para la Argentina la presencia de la "malaria trópica" (producida por *P. falciparum*), la "malaria terciana" (producida por *P. vivax*) y la "malaria cuartana" (producida por *P. malariae*), existiendo además infecciones mixtas (Mühlens et al., 1925). Desde la década de 1970, *P. vivax* aparece como el único parásito causante de la Malaria reportado en el noroeste del país (Bejarano, 1956; Curto et al., 2003; Dantur Juri et al., 2009; World Health Organization, 2010, 2011, 2012).

La Malaria se encuentra ampliamente distribuida tanto en las regiones tropicales como subtropicales de todo el Mundo. Aproximadamente unos 3.400 millones de personas viven en áreas de riesgo de transmisión, reportándose para el 2012, unos 207 millones de enfermos y unas 627.000 muertes debido a esta enfermedad (World Health Organization, 2013). Si bien la mayoría de los enfermos y decesos ocurren en África, el 16 % de la población de América corre riesgo de contraerla y aproximadamente medio millón de personas se enferman cada año (World Health Organization & UNICEF, 2005; Organización Panamericana de la Salud, 2011, World Health Organization, 2013) (Figura 1).

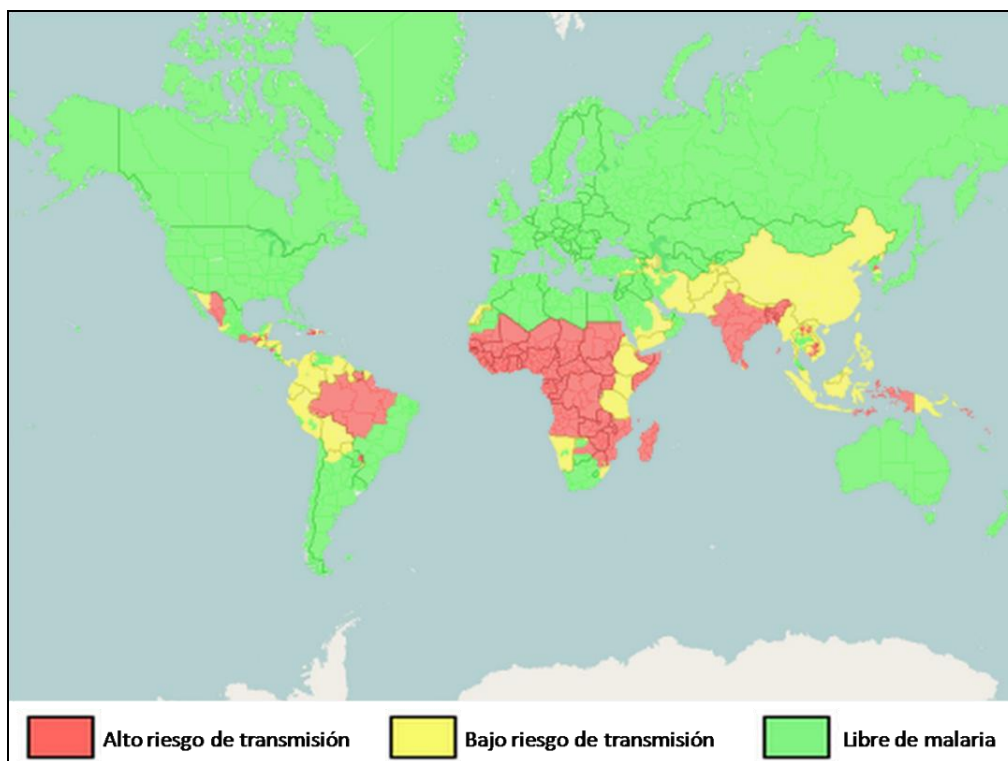


Figura 1. Distribución geográfica de la Malaria en el mundo (extraído de CDC, Center for Disease Control and Prevention, 2014).

En América, la transmisión endémica de la Malaria ocurre en 21 países, entre los que se encuentran, Argentina, Paraguay, Brasil, Bolivia, Perú, Ecuador, Colombia, Venezuela, Guyana, Surinam, Guyana Francesa, Panamá, Costa Rica, Nicaragua, Honduras, El Salvador, Guatemala, Belice, México, Haití y República Dominicana (Rodríguez et al., 2008; World Health Organization, 2013). El número de casos de enfermos disminuyó de 1,1 millón en el 2000 a 469.000 en el 2012. De este total, sólo en tres países se registraron el 76 % de los casos, en Brasil (52 %), en Colombia (13 %) y en Venezuela (10 %). En 13 de los 21 países endémicos (Argentina, Belice, Bolivia, Costa Rica, Ecuador, El Salvador, Guayana Francesa, Guatemala, Honduras, Méjico, Nicaragua, Paraguay y Surinam) la incidencia de la Malaria se redujo más de un 75 % entre el 2000 y el 2012 y se espera que tres países (Brasil, Colombia y Perú) logren reducir la incidencia de la Malaria en más de un 75 % hasta el 2015. Una situación diferente se observó en Guyana y en Venezuela, donde se reportaron

aumentos en la incidencia de casos en 2012 en comparación con el 2010 (World Health Organization, 2013).

En nuestro país, hasta la década del '70, el área malárica abarcaba las provincias de Salta, Jujuy, Tucumán, Santiago del Estero, Catamarca, La Rioja, Formosa, Chaco, Misiones, Corrientes y pequeñas áreas en San Juan, San Luis y Córdoba (Curto et al., 2003). La introducción del DDT (1947) y la implementación del Servicio Nacional de Erradicación del Paludismo en 1959, dentro del Programa de Erradicación de la Malaria de la Organización Panamericana de la Salud (OPS) que incluía también a Bolivia, Paraguay y Brasil, permitieron erradicar la enfermedad en un 96 % de su distribución original (Curto et al., 2003; Dantur Juri et al., 2003; Dantur Juri, 2009), quedando en la actualidad dos focos principales, uno en el noroeste (en las provincias de Salta y Jujuy) de carácter endémico, y otro en el noreste (en la provincia de Misiones) de carácter epidémico (Curto et al., 2003; Organización Panamericana de Salud, 2011) (Figura 2).



Figura 2. Áreas maláricas de Argentina en 2011 (extraído de Malaria Atlas Project, map, 2014)

En la Argentina, el número de casos de enfermos disminuyó desde 1989 hasta 1993, incrementándose nuevamente y alcanzando los 2.048 casos en 1996. Posteriormente, disminuyeron a 592 casos en 1997, 339 en 1998, 222 en 1999, 440 en 2000, 215 en 2001, 125 en 2002, 122 en 2003, 115 en 2004, 259 en 2005 y 209 en 2006. Durante 2007 el número de casos se mantuvo estable y en el 2008 el número de casos por malaria disminuyó en aproximadamente un 50 % con relación al año anterior. A partir de entonces el número continuó disminuyendo reportándose en el 2011 solamente unos 18 casos (World Health Organization, 2012) (Figura 3).

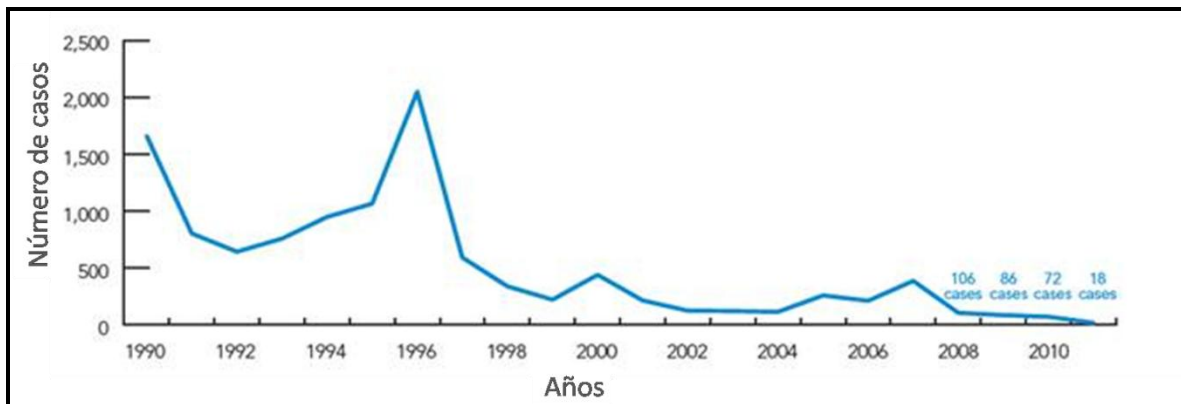


Figura 3. Números de casos reportados de enfermos de Malaria para la Argentina desde 1990 hasta 2011 (extraído de World Health Organization, 2012).

No se han reportado fallecidos por Malaria en las últimas décadas, y el último caso de infección por *P. falciparum* fue registrado en 2007 como un caso importado del exterior. El país se encuentra actualmente en fase de Pre-eliminación de la transmisión autóctona de la Malaria junto con Belice, Costa Rica, Ecuador, El Salvador, Méjico y Paraguay (World Health Organization, 2011; World Health Organization, 2013).

---

### 1.1.2 LOS VECTORES DE LA MALARIA

---

Los subgéneros *Anopheles*, *Nyssorhynchus* y *Kertszia* del género *Anopheles*, incluyen a especies que se encuentran incriminadas en la transmisión de la Malaria. En América se pueden citar a *Anopheles (Nyssorhynchus) albimanus* Wiedemann con su distribución geográfica en las Antillas, México, Venezuela, Colombia y Perú; *Anopheles (Nyssorhynchus) aquasalis* Curry en Venezuela y Brasil; *Anopheles (Anopheles) punctimacula* Dyar and Knab en países de América Central y Colombia; *Anopheles (Nyssorhynchus) nuneztovari* Gabaldon; *Anopheles (Nyssorhynchus) oswaldoi* (Peryassu); *Anopheles (Nyssorhynchus) rangeli* Gabaldon y *Anopheles (Nyssorhynchus)*

*trinkae* Faran en Perú, Colombia y Venezuela. *Anopheles (Nyssorhynchus) albitarsis* Lynch Arribalzaga y *Anopheles (Nyssorhynchus) darlingi* Root se encuentran citadas para la región amazónica de Brasil (Rubio Palis & Zimmermman, 1997) (Figura 4).




Figura 4. Distribución geográfica de algunas especies del género *Anopheles* en América (extraído de Kiszewski et al. 2004).

En nuestro país se encuentran reportadas unas 31 especies de anofelinos que presentan una distribución geográfica característica en el norte del país. Así, en el noroeste fueron citadas 15 especies, entre las cuáles se encuentran, *Anopheles (Anopheles) pseudopunctipennis* Theobald, *Anopheles (Nyssorhynchus) strodei* Root, *Anopheles (Nyssorhynchus) evansae* Brèthes, *An. nuneztovari*, *Anopheles (Nyssorhynchus) rondoni* (Neiva and Pinto), *An. rangeli* y *Anopheles (Nyssorhynchus) argyritarsis* Robineau-Desvoidy. Y en el noreste del país fueron citadas 20 especies encontrándose *An. darlingi*, *Anopheles (Anopheles) apicimacula* Dyar and Knab, *Anopheles (Anopheles) maculipes* (Theobald), *Anopheles (Anopheles) mediopunctatus* (Lutz), *Anopheles (Anopheles) neomaculipalpus* Curry, *An. punctimacula*, *Anopheles*

(*Kerteszia bambusicolus* Komp, *An. albitarsis* y *An. argyritarsis*, entre otras (Dantur Juri, 2009) (Figura 5).




Figura 5. Distribución geográfica de algunas especies de anofelinos en la Argentina (extraído de Augier, 2005).

---

### 1.1.3 EPIDEMIOLOGÍA PANORÁMICA

---

Los recientes avances en la comprensión del ambiente en el cual ocurre la transmisión de muchas enfermedades infecciosas de importancia en salud pública, en particular las transmitidas por vectores, han permitido generar una serie de conceptos y herramientas que están modificando el abordaje de problemas complejos en salud. Así, el uso de sensores remotos y Sistemas de Información Geográfica (GIS) aplicados a eventos epidemiológicos, brindan opciones que se traducen en visiones más integradas de las enfermedades y nuevas posibilidades para prevenirlas y controlarlas (Rodríguez Morales, 2005).



La aplicación de información espacial en temas de salud, también llamada “Epidemiología Panorámica”, es una disciplina relativamente nueva que incluye la caracterización eco-geográfica de aquellas áreas donde se desarrollan las enfermedades, usando para tal fin, técnicas y productos de Teledetección. La Epidemiología Panorámica puede ser considerada como parte de una segunda generación de aplicaciones espaciales, donde el objeto (el vector o reservorio de una enfermedad) no puede ser detectado directamente por los satélites. Es un enfoque holístico, el cual asume que la dinámica biológica entre huéspedes y poblaciones de vectores se ven afectadas por elementos del paisaje, como ser la temperatura y la vegetación (Scavuzzo et al., 2006). La premisa de esta disciplina es entonces que, al ser posible identificar y medir distintas variables ambientales desde el espacio mediante el uso de tecnología satelital, es posible inferir el riesgo de transmisión de enfermedades transmitidas por vectores a diferentes escalas espaciales (Kalluri et al., 2007).

En Latinoamérica, esta disciplina se vio fuertemente impulsada durante el desarrollo del “Workshop sobre tecnología espacial aplicada a la salud humana en beneficio de los países de América Latina y el Caribe” organizado por la Comisión Nacional de Actividades Espaciales (CONAE) y llevado a cabo en Septiembre de 2005 en el Instituto de Altos Estudios Espaciales “Mario Gulich” (Centro Espacial Teófilo Tabanera). Veintiún representantes de la región se reunieron con el objetivo de intercambiar información sobre la situación actual de la práctica de la Epidemiología Panorámica en la región con la finalidad de establecer una red para así estimular el desarrollo de planes operativos (Scavuzzo & Fea, 2005). Resulta importante destacar que uno de los resultados de esta reunión internacional fue la creación del “Grupo Panamericano de Tele-epidemiología” (PTEG) reconocido actualmente por las Naciones Unidas.

---

#### 1.1.4 SISTEMAS DE ALERTA TEMPRANA (PARA PREVENCIÓN DE LA MALARIA)

---

La detección temprana y la prevención de brotes de Malaria constituyen uno de los cuatro elementos técnicos de la Estrategia Global de Control de la Malaria (World Health Organization, 1993). Existe un reconocimiento creciente acerca de la necesidad de implementar programas que permitan predecir brotes de Malaria.

Argentina se encuentra entre los 6 países de América en etapa de Pre-eliminación de la transmisión autóctona de la enfermedad (World Health Organization, 2013). Para los países que se encuentran en esta etapa, la Organización Mundial de la Salud, a través del Plan Global de Acción contra la Malaria (GMAP) de la iniciativa mundial “Roll Back Malaria”, brinda un listado de medidas de control que deben ser llevadas a cabo. Entre estas medidas, la detección temprana de epidemias, es una de las más importantes (Roll Back Malaria, 2008).

Un sistema de alerta temprana que brinda información sobre predicciones espaciales y temporales de epidemias, podría ayudar a controlar y prevenir los brotes de Malaria (Midekisa et. al, 2006) ya que garantiza que las autoridades de salud y los encargados de tomar decisiones, estén conscientes de la amenaza inmediata a la que se enfrentan, y los prepara para tomar medidas de control efectivas (Roll Back Malaria, 2001). Normalmente, los sistemas de detección temprana de Malaria se basan en los registros y diagnósticos mensuales de casos de enfermos reportados por parte de las autoridades de salud, que son los encargados de diagnosticar los casos y brindar el tratamiento efectivo a la población. Si tanto el sistema de vigilancia como los procedimientos de laboratorio, el análisis de datos, el reporte y la notificación de casos se lleva a cabo de manera efectiva, entonces se puede tomar medidas de prevención (con el rociado de insecticidas en áreas de riesgo) y de control (con el diagnóstico por microscopía y búsqueda activa de casos) lo antes posible, priorizando los escasos recursos en las áreas más vulnerables (Midekisa et. al, 2006; Roll Back Malaria, 2008). Este sistema de alerta temprana permite al personal y autoridades de salud estar mejor preparados para prevenir las epidemias o para controlarlas en una etapa temprana (Roll Back Malaria, 2001).

Una de las herramientas utilizadas para el desarrollo de este sistema de alerta temprana es el uso de modelos estadísticos de predicción basados en el reporte histórico de casos e indicadores de riesgo ambientales. De esta manera, el poder cuantificar la relación entre las variables meteorológicas-ambientales y la su incidencia en la aparición de casos de Malaria, es un paso clave hacia una alerta temprana efectiva. Sin embargo, un factor limitante es la falta de datos ambientales y meteorológicos o bien la dificultad para conseguirlos. Es aquí donde los sensores a bordo de distintos satélites para la observación de la tierra, constituyen una fuente de información ambiental fundamental para el desarrollo de modelos predictivos epidemiológicos.

---

#### 1.1.5 TRABAJOS EN ARGENTINA CON SENSORES REMOTOS PARA LA PREDICCIÓN DE EPIDEMIAS

---

Para la Argentina, existen escasos estudios referidos al uso de información satelital para la predicción de casos de enfermedades transmitidas por mosquitos vectores. Rotela et al. (2007) y Estallo et al. (2008, 2012) utilizaron datos referidos a casos de Dengue de la provincia de Salta. Rotela et al. (2007) desarrollaron un modelo de predicción espacio-temporal de casos de Dengue y un mapa predictivo de casos, mediante el uso del test de Knox, de imágenes satelitales Landsat 5 TM y de casos georreferenciados de Dengue durante un brote epidémico en la ciudad de Tartagal, Salta. Reportaron la existencia de tres clusters espacio-temporales, los cuales estaban relacionados a las condiciones espaciales como ser la distancia a los ríos y a la vegetación, entre otras. El mapa predictivo de los casos de Dengue demostró tener un patrón altamente correlacionado (80 %) con el mapa de los casos reales. A su vez, Estallo et al. (2008) desarrollaron modelos de predicción en base a índices larvarios de *Aedes (Stegomyia) aegypti* Linnaeus (Índice de Breteau e Índice de Casas Infestadas) utilizando el índice de vegetación (NDVI, Normalized Difference Vegetation Index) y las variables climáticas (humedad, temperatura y precipitaciones)

para las ciudades de San Ramón de la Nueva Orán y Tartagal, en la provincia de Salta. Utilizando imágenes satelitales Landsat 5 TM desde 2001 a 2005, midieron valores de NDVI sobre una porción de la ciudad y sobre una porción de vegetación vigorosa. Realizaron modelos descriptivos de regresión múltiple a distintas escalas espaciales (a nivel de cada localidad y a nivel regional) y un modelo predictivo (con time lags) a escala regional. Como resultado obtuvieron que para el caso del modelo predictivo, las variables predictivas fueron la precipitación, la temperatura máxima y la humedad. En otro trabajo llevado a cabo por Estallo et al. (2011), se analizó la potencialidad del Índice Normalizado de Agua (NDWI, Normalized Difference Water Index) como variable predictiva del índice larval “Casas Infestadas” de *Ae. aegypti* en la ciudad de San Ramón de la Nueva Orán. El NDWI fue calculado a partir de imágenes Landsat 5 TM durante el período 2001-2005 y fue utilizado como variable independiente junto con el NDVI, la Temperatura de Brillo (TB) y las variables meteorológicas como ser la precipitación, la temperatura y la humedad. Analizaron el grado de correlación entre el índice larval y las variables satelitales y meteorológicas con un retraso temporal de 15 días, desde 1 a 6 meses (retrasos 1-12) mediante regresiones múltiples. El modelo predictivo que utilizó solamente las variables satelitales mostró el mejor ajuste ( $r = 0,64$ ) en relación al que incluyó también las variables climáticas ( $r = 0,54$ ).

Estos trabajos fueron los primeros en llevarse a cabo en el país en el área de predicción de brotes de enfermedades transmitidas por mosquitos vectores a partir de variables ambientales que son claves para dichas enfermedades. En el caso de la Malaria no se han llevado a cabo aún estudios que permitan predecir brotes epidémicos que, como se expuso anteriormente, es una tarea a realizar en aquellos países que se encuentren en etapa de Pre-eliminación de la transmisión de la Malaria.

---

## 1.2 OBJETIVOS

---

Dentro de este contexto, se plantea el siguiente **objetivo general** en el marco de la presente tesis:

Analizar el grado de influencia de los factores ambientales (variables obtenidas de sensores remotos o imágenes satelitales) sobre la aparición de casos de Malaria a fin de generar modelos que sean capaces de predecir brotes epidémicos en San Ramón de la Nueva Orán, departamento Orán (Salta).

Siendo los **objetivos específicos**:

- Analizar los datos epidemiológicos de enfermos de Malaria de San Ramón de la Nueva Orán, reportados para el período 1986-2005.
- Obtener variables ambientales (Índice Normalizado de Vegetación (NDVI), Índice Normalizado de Agua (NDWI) y Temperatura de Superficie (LST)) a partir del pre-procesamiento y procesamiento de imágenes satelitales.
- Utilizar modelos ARIMA (*Autoregressive Integrated Moving Average*) basados en la fluctuación de los casos de Malaria y en las variables ambientales obtenidas en los puntos anteriores a fin de determinar el ajuste del modelo para poder predecir la aparición de nuevos casos y estimar el riesgo de transmisión.
- Analizar la relación existente entre los casos de Malaria reportados y las variables obtenidas de imágenes satelitales mediante análisis de regresión multinivel de Poisson.

---

### 1.3 ÁREA DE ESTUDIO

---

El área de estudio corresponde a la ciudad de San Ramón de la Nueva Orán, ubicada al norte de la provincia de Salta (Figura 6). La ciudad cuenta con 82.413 habitantes (INDEC, 2010), es la segunda ciudad en importancia en la provincia después de Salta Capital, y constituye un importante polo económico en la provincia (Poderti, 1995; García Rodríguez, 2004).




Figura 6. Ubicación del área de estudio en el departamento Orán, provincia de Salta.

La ciudad de San Ramón de la Nueva Orán se encuentra situada en valle de Zenta, enmarcada hacia el oeste por las Serranías de las Mesadas. El relieve del área está determinado por el Sistema Subandino con altitudes que van desde los 350 a los 900 m s.n.m. (Poderti, 1995).

El área de estudio forma parte de la Alta Cuenca del Río Bermejo, pudiéndose encontrar parte de los cauces de los ríos Bermejo, Pescado, Blanco, Santa María y Colorado (Gobierno de la provincia de Salta, 2009). El clima es subtropical con estación seca. Las precipitaciones oscilan entre 700 a 1000 mm anuales concentrándose durante el período estival (noviembre a marzo) (Brown et al., 2009).

La temperatura media anual de 21,4 ° C con valores extremos de hasta 45 ° C. Los inviernos son templados y la humedad del 78 % aproximadamente (Arroyo, 2004).

La ciudad de San Ramón de la Nueva Orán está ubicada en el piso altitudinal correspondiente a la selva pedemontana (entre 400 y 700 m s.n.m.) de las Yungas, más específicamente conocida como la “selva de palo blanco y palo amarillo” con sus árboles característicos *Calycophyllum multiflorum* Griseb y *Phyllostylon rhamnoides* (J. Poiss) Taub. También se encuentran otras especies como el lapacho rosado (*Tabebuia impetiginosa* (Mart. ex DC.) Standl.), el cebil (*Anadenanthera colubrina* (Vell.) Brenan), la quina (*Myroxylon peruiferum* L.f.), la afata (*Cordia trichotoma* (Vell.) Arráb.), el palo lanza (*Patagonula americana* L.), el pacará (*Enterolobium contrortisiliquum* (Vell.) Morong) y el urundel (*Astronium urundeuva* (Allemão) Engl.) (Brown et al., 2006).

El uso del suelo en la región se basa principalmente en los cultivos de caña de azúcar (concentrado en un complejo agro-industrial), cítricos (pomelo, naranja, limón y mandarina), horticultura de primicia (tomate, choclo, zapallito y berenjena), frutales tropicales (banana, palta y mango) y explotación forestal (Eucaliptos y Toona) (Arroyo, 2004).

---

## CAPÍTULO 2: FLUCTUACIÓN DE CASOS DE MALARIA EN SAN RAMÓN DE LA NUEVA ORÁN

---

---

### 2.1 INTRODUCCIÓN

---

El área de frontera argentino-boliviana es una zona de una intensa dinámica epidemiológica en la que se conjugan interacciones patogénicas relacionadas con las condiciones estructurales, climáticas y poblacionales como la dinámica migratoria en ambos sentidos. En la actualidad, el área endémica de la Malaria se encuentra ubicada en el noroeste argentino, pudiéndose diferenciar dos estratos. El estrato I que incluye al extremo norte del departamento Orán y San Martín, con áreas donde hubo viviendas o integrantes de la familia que enfermaron en los últimos 2 ó 3 años. Y el estrato II, que incluye a localidades ubicadas en los departamentos Ledesma y San Pedro (Jujuy) y Anta (Salta) con áreas donde hubo viviendas que históricamente registraron casos autóctonos (Zaidenberg, com. pers.). San Ramón de la Nueva Orán se encuentra dentro del área endémica, a unos 50 km de la frontera con Bolivia. Existe, entre las diferentes localidades, un importante movimiento de la población que por motivos laborales se movilizan diariamente por la zona. La transmisión de la Malaria se ve favorecida por el ingreso de casos importados desde Bolivia, que constituyen una nueva fuente de parásitos en el ciclo de transmisión autóctona (Dantur Juri et al., 2009). Si bien durante la década del '90 bajo las campañas denominadas ARBOL (Argentina-Bolivia) se lograron obtener buenos resultados en relación a la disminución de los casos de Malaria en las dos fronteras, las malas condiciones climáticas comprometieron la accesibilidad en el terreno, favoreciendo la discontinuidad de las acciones de control (Curto et al., 2003). Aun así, el número de casos autóctonos de Malaria fue disminuyendo hasta la actualidad llegando a cero,



estando por ende la Argentina incluida en la fase de Pre-Eliminación de la transmisión de la Malaria de acuerdo a la Organización Mundial de la Salud.

Dentro de este contexto, es que se plantea como **objetivo principal** de este capítulo, analizar la fluctuación temporal de los casos de Malaria registrados desde enero de 1986 a diciembre de 2005 en la ciudad de San Ramón de la Nueva Orán (departamento Orán, provincia de Salta).

Cabe aclarar, que se describen las características de una serie temporal de casos de Malaria reportados por los técnicos de la Coordinación Nacional de Control de Vectores delegación Salta, del Ministerio de Salud de la Nación. En base a esta información se analizó la fluctuación temporal de los mismos a fin de observar si existe un patrón temporal (por ejemplo, en estaciones) y se realiza un análisis descriptivo de los casos de Malaria.

---

## 2.2 MATERIALES Y MÉTODOS

---

---

### 2.2.1 OBTENCIÓN DE DATOS EPIDEMIOLÓGICOS

---

Los datos de los casos de enfermos de Malaria fueron extraídos de planillas confeccionadas por personal técnico de la Base Operativa de Orán del Programa Nacional de Control de Vectores, delegación Salta, del Ministerio de Salud de la Nación. Estas planillas contienen datos aportados por los enfermos, entre los cuales figuran: fecha (día, mes, año), nombre del enfermo, domicilio del mismo, lugar de contagio de la enfermedad, viajes realizados durante los últimos meses, ocupación, nacionalidad del enfermo y clasificación correspondiente al caso (autóctono, introducido o importado, según el lugar donde fue contraída la enfermedad). Los datos de estas planillas fueron digitalizados en planillas Excel. Los casos fueron registrados a escala mensual. En este trabajo se utilizaron los casos de Malaria reportados como

autóctonos e introducidos y se excluyeron los casos importados bajo el supuesto de que las fluctuaciones en las variables climáticas a nivel local, habrían influido en la aparición de casos autóctonos e introducidos, no así sobre la aparición de casos importados.

---

### 2.2.2 FLUCTUACIÓN DE CASOS EN SAN RAMÓN DE ORÁN

---

Se analizó la fluctuación de los casos autóctonos/introducidos de Malaria desde enero de 1986 hasta diciembre de 2005 con el fin de determinar si existía un patrón estacional de la enfermedad.

El número total de casos reportados autóctonos/introducidos de Malaria durante un período de 20 años comprendido entre enero de 1986 y diciembre de 2005 en San Ramón de la Nueva Orán fue de 453 casos. Los picos más elevados de casos de enfermos se produjeron en el año 1996 durante los meses de enero, febrero y abril con 41, 24 y 25 casos respectivamente. Se observó otro pico importante en el mes de febrero de 1997 con 24 enfermos de Malaria. Hubo años en los que no se registró transmisión de Malaria como ser el año 1986. Y, a partir del año 2000, el número de casos reportados es casi nulo, observándose la ocurrencia esporádica de 1 o 2 casos durante los meses de verano. Un total de 23 casos fueron notificados desde enero de 2000 hasta diciembre de 2005 (Figura 7).




Figura 7. Fluctuación temporal de casos autóctonos/introducidos de Malaria reportados en San Ramón de la Nueva Orán, provincia de Salta.

Al analizar la ocurrencia de los casos de Malaria en relación a los meses del año, puede observarse un patrón estacional en el que la mayor cantidad de casos se reportaron durante los meses de verano (de diciembre a marzo) (Figura 8).

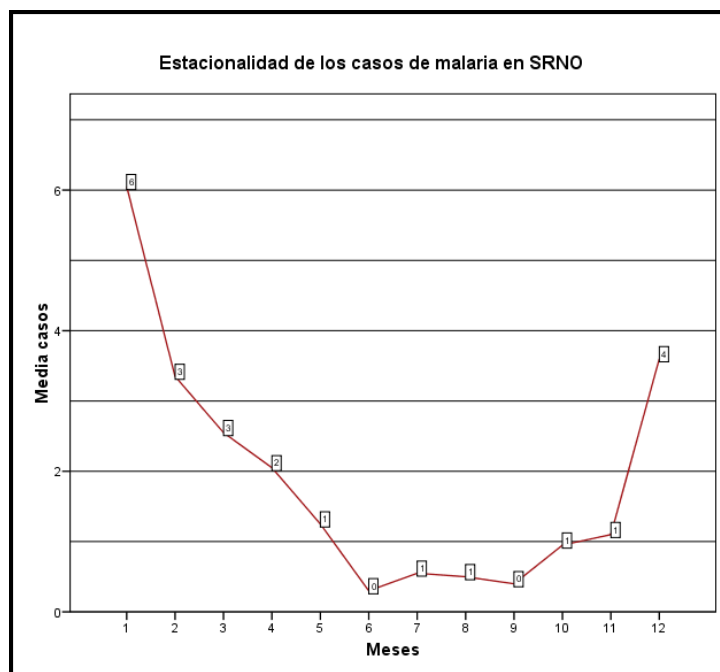


Figura 8. Media de los casos de Malaria por mes desde 1986 hasta 2005 en San Ramón de la Nueva Orán, Salta.

---

### 2.2.3 ANÁLISIS DESCRIPTIVO DE LOS CASOS DE MALARIA DURANTE EL PERÍODO 1986-2005

---

Se procedió a determinar las características sociodemográficas y frecuencias relativas de los casos de Malaria. Mediante el uso del programa Excel, se realizaron gráficas descriptivas para cada una de las variables consideradas tales como: “sexo”, “grupo etario” y “ocupación”.

Teniendo en cuenta el sexo de las personas enfermas de Malaria, se analizó la frecuencia con que ocurrieron anualmente durante el período 1986-2005. Se observó

que en todos los años, la mayoría de los casos correspondieron al sexo masculino (en una proporción mayor al 50 %) (Figura 9).




Figura 9. Casos de Malaria de acuerdo al sexo (Masculino y Femenino) reportados anualmente para el período 1986-2005.

Considerando la edad de las personas enfermas de Malaria para el periodo de 1986 a 2005, se observó que la mayor frecuencia de enfermos fue la comprendida en el grupo etario de 15-30 años (Figura 10).




Figura 10. Casos de enfermos de Malaria divididos en grupos etarios para el periodo 1986-2005.

143 casos de enfermos de Malaria se encuentran incluidos dentro del grupo etario de 15-30 años de edad. 127 casos se registraron en el grupo etario de 31-45 años, y en tercer lugar, 96 casos se registraron en el grupo etario de 0-15 años de edad (Figura 10).

Por último, se analizó la frecuencia de los casos de enfermos de Malaria durante el período de estudio, teniendo en consideración la ocupación laboral de las personas. Los diferentes tipos de trabajo fueron agrupados de acuerdo a si la actividad laboral fue llevada a cabo en zonas rurales (“campo”) o en el área urbana (“ciudad”). Los menores de edad y escolares, que no llevaron a cabo tareas laborales, fueron agrupados en el grupo “Menor” (Figura 11).

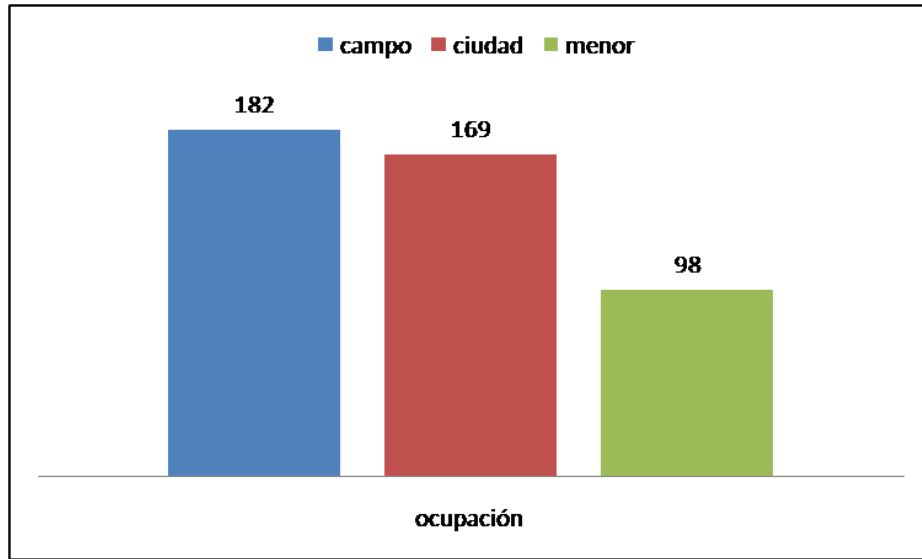


Figura 11. Frecuencia de casos de enfermos de Malaria de acuerdo a la ocupación durante el periodo 1986-2005.

182 casos de enfermos de Malaria se encuentran incluidos en el grupo “campo”, seguidos por 169 casos del grupo “ciudad”, y en una proporción mucho menor el grupo correspondiente a “menor”.

---

# CAPÍTULO 3: OBTENCIÓN DE SERIES TEMPORALES A PARTIR DE IMÁGENES SATELITALES

---

---

## 3.1 INTRODUCCIÓN

---

El **objetivo principal** de este capítulo fue, mediante la obtención de una serie temporal de imágenes satelitales Landsat, conseguir analizar la fluctuación temporal de las variables ambientales para ser utilizadas luego como variables predictivas en la aparición de los casos de Malaria.

En el presente capítulo se describe la metodología utilizada para la generación de una serie temporal de imágenes Landsat del área de estudio, a partir de la cual se obtuvieron la variable temperatura de superficie (LST) y se calcularon el Índice Normalizado de Vegetación (NDVI) y el Índice Normalizado de Agua (NDWI). En base a esta información y mediante el uso de un código implementado en IDL se obtuvieron 3 series temporales (una por cada variable) mostrando la fluctuación de las mismas durante el periodo de estudio. Se presentan además los pasos de pre-procesamiento de imágenes satelitales Landsat así como los pasos requeridos para la generación de las series temporales mencionadas. A su vez, se comparan las imágenes resultantes de la calibración utilizando, por un lado, una adaptación de un algoritmo en R y, por otro, el paquete de R “Remote Sensing”.

---

### 3.1.1 CARACTERÍSTICAS DE LAS IMÁGENES LANDSAT

---

Los satélites Landsat forman parte de un programa de la NASA en conjunto con el Servicio Geológico de Estados Unidos (USGS). Este programa representa la



colección de datos espaciales, más larga y continua del mundo, obtenida a partir de sensores remotos de resolución espacial moderada. El proyecto comenzó con el lanzamiento del satélite Landsat 1 en 1972, y continúa hoy en la actualidad con el satélite Landsat 8, lanzado a principios de 2013 (Figura 12).




Figura 12. Misiones Landsat en el tiempo.

Son siete los satélites Landsat (Landsat 6 falló en el lanzamiento) que, a través de cuatro décadas de imágenes, proporcionan un recurso único para quienes trabajan en agricultura, geología, silvicultura, planificación regional, educación, cartografía e investigación sobre el cambio climático, entre otros. Las imágenes Landsat son también de un valor incalculable para dar soporte en la respuesta a emergencias (USGS, 2014)

Los satélites Landsat orbitan a una altitud de 705 Km. Cada imagen cubre un área de 185 x 185 Km., poseen una inclinación solar de 98.2°, con órbita polar helio sincrónica, una revisita de 16 días y pasando por el Ecuador a las 9:45 AM ( $\pm 15$  min.) hora local (en modo descendente).

Los principales sensores fueron el *Thematic Mapper* (TM) a bordo de los satélites Landsat 3, 4 y 5 y el *Enhanced Thematic Mapper Plus* (ETM+) a bordo del Landsat 7. En la actualidad, el Landsat 8 ya no consta de estos sensores sino que lleva a bordo los instrumentos *Operational Land Imagen* (OLI) y *Thermal Infrared Sensor* (TIRS).

El sensor TM, opera en siete bandas espectrales diferentes elegidas especialmente para el monitoreo de vegetación a excepción de la banda 7, que se agregó para aplicaciones geológicas. La imagen posee un tamaño de píxel en todas las

bandas de 30 metros, a excepción de la banda termal 6, que tiene un píxel de 120 metros en el terreno, presentando las siguientes características:

- Banda 1: (0,45 a 0,52 micrones - azul) fue diseñada para la penetración en cuerpos de agua, y es útil para el mapeo de costas, para diferenciar entre suelo y vegetación y para clasificar distintas cubiertas boscosas como por ejemplo coníferas y latifoliadas. También es útil para diferenciar los diferentes tipos de rocas presentes en la superficie terrestre.

- Banda 2: (0,52 a 0,60 micrones - verde) fue especialmente diseñada para evaluar el vigor de la vegetación sana, midiendo su pico de reflectancia (o radiancia) en el espectro del verde. También es útil para diferenciar tipos de rocas.

- Banda 3: (0,63 a 0,69 micrones - rojo) es una banda de absorción de clorofila, muy útil para la clasificación de la cubierta vegetal. También sirve en la diferenciación de tipos de rocas.

- Banda 4: (0,76 a 0,90 micrones - infrarrojo cercano) es útil para determinar el contenido de biomasa, para la delimitación de cuerpos de agua y para la clasificación de las rocas.

- Banda 5: (1,55 a 1,75 micrones - infrarrojo medio) es indicativa del contenido de humedad de la vegetación y del suelo, y es útil para discriminar nieve y nubes.

- Banda 6: (10,40 a 12,50 micrones - infrarrojo termal o infrarrojo térmico) es útil en el análisis del estrés de la vegetación, en la determinación de la humedad del suelo y en el mapeo termal o de temperatura de superficie.

- Banda 7: (2,08 a 2,35 micrones - infrarrojo lejano) fue especialmente diseñada por su potencial para la discriminación de rocas y para el mapeo hidrotermal. Mide la absorción de agua.

El sensor ETM+ a bordo del Landsat 7, presenta las mismas bandas que su antecesor TM, a las que se agrega otra banda térmica (la banda 6 en este caso registra una imagen con alta ganancia y otra con baja ganancia (*Low Gain* y *High Gain*)) y una banda pancromática (0,52 a 0,90 micrones) de alta resolución espacial (píxel de 15 metros).

## 3.2 MATERIALES Y MÉTODOS

---

### 3.2.1 SELECCIÓN DE LAS IMÁGENES LANDSAT

---

Debido a que la resolución temporal de los datos epidemiológicos utilizados posee una frecuencia de registro mensual, se generó una serie temporal de imágenes satelitales Landsat de frecuencia mensual cuasi equivalente (240 imágenes desde enero de 1986 a diciembre de 2005). Debido a la cobertura nubosa sobre el área de interés o bien a la falta de imágenes disponibles para algunos meses, no fue posible construir la serie temporal completa. Por ello se implementó un algoritmo de interpolación en IDL para estimar los datos faltantes y construir una serie temporal concordante con la serie epidemiológica. Este procedimiento se detallada en este capítulo.

Las imágenes Landsat se obtuvieron de tres organismos distintos: el USGS, el GLCF (Global Land Cover Facility: iniciativa de la Universidad de Maryland en Estados Unidos, con apoyo de la NASA) y del Instituto de Pesquisas Espaciais (INPE, Brasil). La búsqueda se realizó a través de los sitios de descarga en internet de cada institución:

USGS: Earth Explorer: <http://earthexplorer.usgs.gov/>

GLCF: Earth Science Data Interface (ESDI): <http://glcfapp.glcg.umd.edu:8080/esdi/>

INPE: Datos de Satélite: <http://www.dgi.inpe.br/CDSR/>

Los mismos permiten realizar búsquedas de las escenas en base a la fecha de captura, la zona de estudio, satélite y tipo de sensor, entre otros. Debido a que el área de estudio se encuentra en el límite de dos pasadas contiguas del satélite: path: 230/231; row: 076 en el sistema WRS-2 (*World Reference System*) es posible sensarla en ambas escenas, por lo que existe una cantidad importante de imágenes disponibles (Figura 13).



Figura 13. Área de estudio (rectángulo rojo) en dos escenas de pasadas contiguas del satélite. Path 231 (escena de la izquierda) y path 230 (escena de la derecha).

La búsqueda se realizó en las tres instituciones, en base al periodo y área de estudio, y se analizó visualmente cada imagen (para determinar si el área de interés se encontraba cubierta de nubes). Se generó un **catálogo** en Excel, para especificar las imágenes disponibles (a la fecha de descarga) en cada institución.

En los meses con más de una imagen disponible, debido a la revisita de 16 días de Landsat, se escogió una de las imágenes teniendo en cuenta la equidistancia temporal con las fechas de adquisición del mes precedente y del mes posterior. En total se realizó la descarga de 160 imágenes Landsat 4 y 5 TM, y 16 Landsat 7 ETM+. La fecha de adquisición y la fuente de las mismas se muestra en el anexo A. Las imágenes poseían las bandas en archivos separados en formato .TIFF y un archivo metadato en formato .MTL. El sistema de referencia de las imágenes fue UTM\_WGS84.

---

## 3.2.2 PRE PROCESAMIENTO

---

### 3.2.2.1. CALIBRACIÓN

---

Las imágenes satelitales están constituidas por una matriz numérica donde en cada celda se encuentra un valor numérico llamado Número Digital (ND), el cual está asociado a un valor de radiancia, que es la energía irradiada por unidad de área y por

ángulo sólido. La calibración radiométrica consiste en transformar los ND a unidades de radiancia, es decir, al parámetro físico que el sensor mide.

Existe una relación lineal entre los ND y la radiancia ya que los ND son simplemente los valores de radiancia escalados a valores de 1 a 255 (para imágenes satelitales de 8 bits de resolución radiométrica). Por lo tanto, la conversión de DN a radiancia es relativamente sencilla según una función lineal (Figura 14).

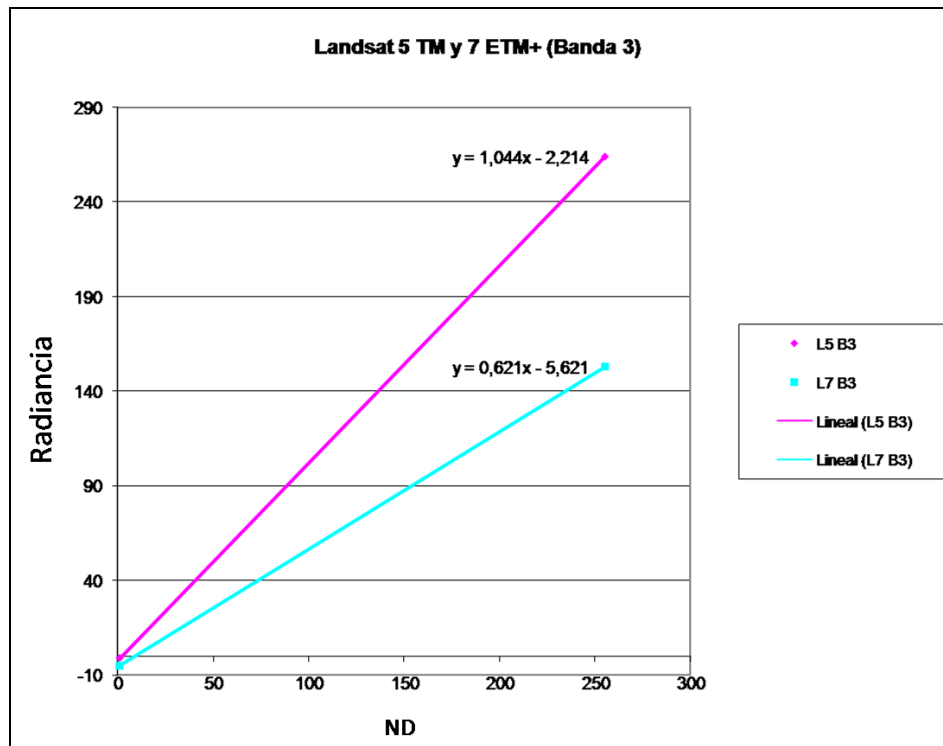


Figura 14. Relación entre los ND y la radiancia para la banda 3 (rojo) de los sensores TM (Landsat 5) y ETM+ (Landsat 7)

### 3.2.2.1.1 CÁLCULO DE LA RADIANCIA

Los ND pueden convertirse a valores de radiancia a partir de los coeficientes de calibración del sensor. Los valores de estos parámetros se encuentran en el archivo de metadatos.

En el caso de la misión Landsat la ecuación de calibración es la siguiente:

$$L_{\lambda} = ((L_{MAX\lambda} - L_{MIN\lambda}) / (Q_{calmax} - Q_{calmin})) * (Q_{cal} - Q_{calmin}) + L_{MIN\lambda}$$

ó

$$L_{\lambda} = G_{rescale} \times Q_{cal} + B_{rescale}$$

Donde

$$G_{rescale} = (L_{MAX\lambda} - L_{MIN\lambda}) / (Q_{calmax} - Q_{calmin})$$

$$B_{rescale} = L_{MIN\lambda} - ((L_{MAX\lambda} - L_{MIN\lambda}) / (Q_{calmax} - Q_{calmin})) * Q_{calmin}$$

Donde  $L_{\lambda}$  = la radiancia espectral recibida por el sensor en la longitud de onda  $\lambda$  [en W/m<sup>2</sup> sr  $\mu$ m].

$G_{rescale}$  = ganancia de dicha banda ("gain") [en W/(m<sup>2</sup> sr  $\mu$ m)]/DN].

$B_{rescale}$  = "offset" o "bias".

$Q_{cal}$  = nivel digital (ND) que se desea convertir.

$L_{MIN\lambda}$  = radiancia espectral en la banda  $\lambda$  correspondiente a  $Q_{calmin}$ .

$L_{MAX\lambda}$  = radiancia espectral en la banda  $\lambda$  correspondiente a  $Q_{calmax}$ .

$Q_{calmax}$  = nivel digital mínimo calibrado (usualmente = 1).

$Q_{calmin}$  = nivel digital máximo calibrado (usualmente = 255).

Los valores de Gain y Bias varían según la banda espectral y el sensor de que se trate (Tabla 1) (Tabla 2).

TM Sensors ( $Q_{calmin} = 1$ and $Q_{calmax} = 255$ )							
Band	Spectral range	Center wavelength	LMIN <sub><math>\lambda</math></sub>	LMAX <sub><math>\lambda</math></sub>	G <sub>rescale</sub>	B <sub>rescale</sub>	ESUN <sub><math>\lambda</math></sub>
Units	$\mu\text{m}$		W/(m <sup>2</sup> sr m)		(W/m <sup>2</sup> sr m)/DN	W/(m <sup>2</sup> sr m)	W/(m <sup>2</sup> m)
<b>L4 TM (NLAPS)</b>							
1	0.452 – 0.518	0.485	-1.52	152.10	0.602431	-1.52	1983
2	0.529 – 0.609	0.569	-2.84	296.81	1.175098	-2.84	1795
3	0.624 – 0.693	0.659	-1.17	204.30	0.805765	-1.17	1539
4	0.776 – 0.905	0.841	-1.51	206.20	0.814549	-1.51	1028
5	1.568 – 1.784	1.676	-0.37	27.19	0.108078	-0.37	219.8
6	10.42 – 11.66	11.040	1.2378	15.3032	0.055158	1.2378	N/A
7	2.097 – 2.347	2.222	-0.15	14.38	0.056980	-0.15	83.49
<b>L4 TM (LPGS)</b>							
1	0.452 – 0.518	0.485	-1.52	163	0.647717	-2.17	1983
			-1.52	171	0.679213	-2.20	
2	0.529 – 0.609	0.569	-2.84	336	1.334016	-4.17	1795
3	0.624 – 0.693	0.659	-1.17	254	1.004606	-2.17	1539
4	0.776 – 0.905	0.841	-1.51	221	0.876024	-2.39	1028
5	1.568 – 1.784	1.676	-0.37	31.4	0.125079	-0.50	219.8
6	10.42 – 11.66	11.040	1.2378	15.3032	0.055376	1.2378	N/A
7	2.097 – 2.347	2.222	-0.15	16.6	0.065945	-0.22	83.49
<b>L5 TM (LPGS)</b>							
1	0.452 – 0.518	0.485	-1.52	169	0.671339	-2.19	1983
			-1.52	193	0.765827	-2.29	
2	0.528 – 0.609	0.569	-2.84	333	1.322205	-4.16	1796
			-2.84	365	1.448189	-4.29	
3	0.626 – 0.693	0.660	-1.17	264	1.043976	-2.21	1536
4	0.776 – 0.904	0.840	-1.51	221	0.876024	-2.39	1031
5	1.567 – 1.784	1.676	-0.37	30.2	0.120354	-0.49	220.0
6	10.45 – 12.42	11.435	1.2378	15.3032	0.055376	1.18	N/A
7	2.097 – 2.349	2.223	-0.15	16.5	0.065551	-0.22	83.44

Tabla 1. Rango espectral, parámetros de calibración e irradiancia solar exoatmosférica media (ESUN) del sensor TM (extraída de Chander et al., 2009).

Las imágenes del sensor **ETM+** son adquiridas en modo de alta ganancia (“*high gain*”) y de baja ganancia (“*low gain*”). El objetivo de usar imágenes con dos ganancias distintas es maximizar la resolución radiométrica de 8 bits sin saturar los detectores del sensor. Para todas las bandas, el rango de la ganancia baja es aproximadamente 1,5 veces el rango de la ganancia alta. Por lo tanto, el modo de ganancia baja se usa cuando la superficie censada es brillante mientras que el de ganancia alta se usa cuando el brillo de la superficie es bajo. Para aplicar la fórmula de calibración es necesario saber cuál ganancia se debe usar, lo cual viene determinado por el tipo de cobertura terrestre que domina la imagen satelital (Tierra Firme (no desértica ni con hielo), Desiertos, Hielo/Nieve, Agua, Aguas Oceánicas, Zona de volcanes) y por el mes del año en que se realiza la captura de la imagen. Esta información se encuentra disponible en : [http://landsathandbook.gsfc.nasa.gov/data\\_properties/prog\\_sect6\\_4.html](http://landsathandbook.gsfc.nasa.gov/data_properties/prog_sect6_4.html)).

Los parámetros de calibración del sensor ETM+ para ambos modos puede ser observado en la Tabla 2.

L7 ETM+ Sensor ( $Q_{calmin} = 1$ and $Q_{calmax} = 255$ )							
Band	Spectral range	Center wavelength	LMIN <sub>λ</sub>	LMAX <sub>λ</sub>	G <sub>rescale</sub>	B <sub>rescale</sub>	ESUN <sub>λ</sub>
Units	μm		W/(m <sup>2</sup> sr μm)		(W/m <sup>2</sup> sr μm)/DN	W/(m <sup>2</sup> sr μm)	W/(m <sup>2</sup> μm)
<i>Low gain (LPGS)</i>							
1	0.452–0.514	0.483	–6.2	293.7	1.180709	–7.38	1997
2	0.519–0.601	0.560	–6.4	300.9	1.209843	–7.61	1812
3	0.631–0.692	0.662	–5.0	234.4	0.942520	–5.94	1533
4	0.772–0.898	0.835	–5.1	241.1	0.969291	–6.07	1039
5	1.547–1.748	1.648	–1.0	47.57	0.191220	–1.19	230.8
6	10.31–12.36	11.335	0.0	17.04	0.067087	–0.07	N/A
7	2.065–2.346	2.206	–0.35	16.54	0.066496	–0.42	84.90
PAN	0.515–0.896	0.706	–4.7	243.1	0.975591	–5.68	1362
<i>High Gain (LPGS)</i>							
1	0.452–0.514	0.483	–6.2	191.6	0.778740	–6.98	1997
2	0.519–0.601	0.560	–6.4	196.5	0.798819	–7.20	1812
3	0.631–0.692	0.662	–5.0	152.9	0.621654	–5.62	1533
4	0.772–0.898	0.835	–5.1	157.4	0.639764	–5.74	1039
5	1.547–1.748	1.648	–1.0	31.06	0.126220	–1.13	230.8
6	10.31–12.36	11.335	3.2	12.65	0.037205	3.16	N/A
7	2.065–2.346	2.206	–0.35	10.80	0.043898	–0.39	84.90
PAN	0.515–0.896	0.706	–4.7	158.3	0.641732	–5.34	1362

Tabla 2. Rango espectral, rangos de post-calibración e irradiancia solar exoatmosférica media (ESUN) de ETM+ (extraída de Chander et al., 2009).

### 3.2.2.1.2 CÁLCULO DE LA REFLECTANCIA

Luego de haber obtenido la radiancia espectral es necesario calcular la reflectancia total exoatmosférica, TOA, también conocida como el albedo planetario de cada banda.

Cuando se comparan datos de diferentes escenas hay tres ventajas relacionadas al uso de TOA en lugar de radiancia absoluta. En primer lugar se corrige el efecto del coseno de los diferentes ángulos cenitales solares debido a cambios temporales o geográficos en la adquisición de la imagen. En segundo lugar, el TOA compensa los diferentes valores de irradiancia solar exoatmosférica correspondientes a cada banda. Tercero, el TOA corrige las variaciones debido a la distancia entre la Tierra y el Sol que depende de la fecha de toma de la imagen.

La reflectancia TOA de la Tierra se calcula mediante la ecuación:

$$\rho_{\lambda} = (\pi * L_{\lambda} * d^2) / (ESUN_{\lambda} * \cos \theta_s)$$



donde

$\rho_\lambda$  = Reflectancia planetaria el tope de la atmósfera, TOA [adimensional].

$\pi$  = Constante matemática igual a 3.14159 [adimensional].

$L_\lambda$  = Radiancia espectral en la apertura del sensor, [W/(m<sup>2</sup> sr  $\mu$ m)].

$d$  = Distancia entre la Tierra y el Sol [unidades astronómicas].

$ESUN_\lambda$  = Irradiancia solar exoatmosférica media [W/ (m<sup>2</sup>  $\mu$ m)].

$\theta_s$  = ángulo cenital solar [grados].

El ángulo cenital solar es función del tiempo, del día del año y de la latitud. El coseno del ángulo cenital solar es igual al seno del ángulo de elevación solar. Este último se encuentra incluido en los metadatos de los productos L1 de las imágenes LANDSAT. La tabla de distancia al sol en función del día juliano como así también los valores de  $ESUN_\lambda$  para cada banda del sensor TM y ETM+ fueron publicados por Chander et al. (2009).

### 3.2.2.1.3 CÁLCULO DE LA TEMPERATURA DE BRILLO

La banda térmica, TM6, puede convertirse de radiancia espectral en la apertura del sensor a Temperatura de brillo en grados Kelvin. Para la temperatura de brillo del sensor se asume que la superficie terrestre es un cuerpo negro (se considera que su emisividad es igual a 1) e incluye efectos atmosféricos de absorción y emisión a lo largo del camino óptico. Para realizar este cálculo se utilizan las constantes de calibración publicadas en Chander et al. (2009). La temperatura de brillo de la Tierra a partir de la radiancia espectral en la apertura del sensor de la banda térmica se calcula utilizando la siguiente ecuación:

$$T = k_2 / \ln((k_1 / L_\lambda) + 1)$$

Donde

T= Temperatura de Brillo efectiva medida en el sensor [K].

k2= Constante de calibración 2 [K].

k1= Constante de Calibración 1 [W/(m<sup>2</sup> sr μm)].

L<sub>λ</sub> = Radiancia espectral en la apertura del sensor [W/(m<sup>2</sup> sr μm)].

ln= Logaritmo natural

Las constantes de la calibración para la banda térmica varían según el sensor (Tabla 3).

Constant	K1	K2
Units	W/(m <sup>2</sup> sr μm)	Kelvin
L4 TM	671.62	1284.30
L5 TM	607.76	1260.56
L7 ETM+	666.09	1282.71

Tabla 3. Constantes de calibración de la banda térmica de TM y ETM+ (extraída de Chander et al., 2009).

El producto L1 del sensor ETM+ posee dos bandas termales, una adquirida usando el modo en baja ganancia (referida frecuentemente como Banda 6 L) y otra usando el modo en alta ganancia (referida como Banda 6 H). En este trabajo, para el cálculo de la temperatura, se utilizó la banda correspondiente al modo de alta ganancia.

### 3.2.2.2 METODOLOGÍA PARA LA CALIBRACIÓN DE LAS IMÁGENES LANDSAT

Las imágenes satelitales descargadas contienen valores de radiancia guardados en 8 bits (ND con valores entre 1 y 255). Por este motivo fue necesario calibrar cada banda para obtener en primera instancia los valores de radiancia y luego los valores de reflectancia en el caso de las bandas 1-5 y 7, y de temperatura en el caso de la de la banda térmica 6, expresada en grados Kelvin.

Existen diversas maneras de calibrar una imagen satelital y estas maneras difieren entre sí en los pasos a seguir para lograr la calibración. Puede realizarse mediante softwares de procesamiento de imágenes, los cuales traen un módulo para calibrar o puede realizarse mediante algoritmos computacionales (lo que se conoce como *scripts*). En este trabajo se consideraron tres maneras distintas de calibración:

A)-script de calibración en R

B)-módulo de calibración en el Paquete “Remote Sensing” de R

C)-módulo “Landsat calibration” del programa ENVI 4.8

Se calibraron las bandas 3 y 4 de una sola imagen Landsat y se compararon los valores de reflectancia de un determinado pixel, dentro de la imagen calibrada con las tres metodologías:

A). *Script de calibración en R*

Se tomó un script realizado por la Dra. Anabella Ferral durante su tesis de maestría AEARTE en 2012: “Este código en R fue hecho para calcular radiancia espectral, reflectancia y temperatura de brillo de imágenes LANDSAT5-TM provistas por la CONAE. Para las bandas TM1, TM2, TM3, TM4, TM5 y TM7 el archivo de salida son imágenes de reflectancia, mientras que para la banda TM6 es una de temperatura de brillo. El programa solo requiere como dato de entrada el nombre del directorio que contiene la imagen satelital y un archivo de texto con una tabla de valores de distancia al sol para cada día juliano del año. El código aplica las ecuaciones de calibración e incluye las constantes necesarias. Los parámetros como ángulo de elevación solar o fecha de adquisición de la imagen son leídos automáticamente del archivo de los metadatos (header) de la imagen. El formato de entrada es FAST FORMAT REV B y el de salida es de una imagen Standard de Envi con siete bandas, seis con datos de reflectancia (B1, B2, B3, B4, B5, B7) y uno con el de temperatura de brillo (B6)” (extraído de Ferral, 2012).

Para esta tesis se modificó este script y se lo adaptó para la calibración de imágenes Landsat 5 TM y Landsat 7 ETM+. La modificación incluyó el agregado de un

comando para la lectura automática de los metadatos en busca de los parámetros de calibración.

-

#### *B)- Calibración con el paquete R*

El paquete “**Remote Sensing**” es un paquete de R que procesa imágenes satelitales Landsat, MODIS, Aster, NOAA (sensor AVHRR). Presenta distintos módulos de pre-procesamiento de imágenes los cuales calibran, remueven nubes (en imágenes Landsat) y calculan índices de vegetación e índices de agua. El paquete se encuentra disponible para los sistemas operativos de Windows, Linux y Mac.

Utilizando la función “dn2ref” de este paquete, se obtuvo un archivo .tiff que contiene las bandas 1, 2, 3, 4, 5 y 7 (en valores de reflectancia) y por otro lado, la banda 6 calibrada en un archivo separado (en grados Kelvin). Para la calibración de la banda 6 se utilizó la función “dn2temp” del mismo paquete. La función de calibración de este paquete calibra imágenes Landsat de los sensores MSS, TM y ETM+. No calibra imágenes de Landsat 8 ya que el paquete fue creado antes del lanzamiento del mismo.

#### 3.2.2.2.1 RESULTADOS DE LA CALIBRACIÓN.

En la Tabla 4 se observan los resultados obtenidos al medir con ENVI 4.8 el valor medio de reflectancia para una muestra de 400 píxeles de una imagen calibrada con tres métodos de calibración distintos: con el script modificado para esta tesis, el módulo “dn2ref” del paquete “Remote Sensing” de R y el módulo de calibración de ENVI 4.8 “Landsat Calibration” (a pesar de que desde un principio se decidió no utilizar este último, se procedió a calibrar con el mismo para comparar el resultado con de los otros dos métodos).

	<b>Script R</b>	<b>Dn2ref (paq RS)</b>	<b>ENVI</b>
<b>Banda 3</b>	0.112950	0.111567	0.112873
<b>Banda 4</b>	0.259364	0.258018	0.259251

Tabla 4. Valores medios de reflectancia (entre 0 y 1) de una muestra de 400 pixeles de la imagen Landsat 7 ETM de la fecha 06 de julio de 2002 (path y row: 230/076) calibrada usando las tres metodologías.

### 3.2.2.2.2 CONCLUSIONES DE LA CALIBRACIÓN

Se puede observar en la Tabla 4 que la reflectancia medida es la misma hasta los dos primeros decimales y que a partir de los tres decimales existen algunas diferencias entre ellas. Si se tiene en cuenta que para este trabajo no es importante que la calibración sea tan precisa, puede considerarse que usando dos decimales, el resultado es el mismo usando las distintas metodologías. Esto demuestra que el script que se modificó para esta tesis al igual que paquete de R, funcionan correctamente para la calibración de imágenes Landsat.

Para calibrar las imágenes en este trabajo se decidió utilizar el paquete “Remote Sensing” porque para realizar la calibración solo bastan tres líneas de comando en las que el usuario el único dato que debe ingresar es el nombre de la imagen de salida. Esto presenta una enorme ventaja al momento de calibrar grandes cantidades de imágenes ya que, a diferencia de otros paquetes u otros métodos, no es necesario abrir el archivo de metadatos en busca de los parámetros de calibración (como sucede si calibramos con ENVI), ya que el paquete lee el metadato automáticamente. Además este paquete, calibra imágenes de todos los sensores Landsat (a excepción del Landsat 8) mientras que para esta tesis, a partir del script de la Dra. Ferral, se crearon dos scripts de calibración: uno para Landsat 5 y otro para Landsat 7.

Una vez calibradas las bandas se calcularon el NDVI y el NDWI con RStudio usando la función “ndvi” y “ndwi” del paquete “Remote Sensing” de R. El NDWI

calculado por el paquete de R corresponde al NDWI de Gao (1996) (Yann Chenin, com. pers.).

---

### 3.2.2.3 GEORREFERENCIACIÓN

---

Se eligieron 3 imágenes satelitales provenientes de las distintas fuentes para probar si se encontraban bien georreferenciadas, es decir si las coordenadas de las mismas correspondían exactamente con coordenadas geográficas reales. Se tomó como coordenadas reales a las coordenadas de Google Earth. Mediante la superposición de la imagen Landsat del USGS sobre la de Google Earth, se pudo comprobar que existía una correspondencia geográfica entre ambas. Se utilizó entonces esta imagen Landsat como base para la georreferenciación.

Se comprobó que las imágenes provenientes del INPE no se encontraban bien georreferenciadas. Mediante el uso del software ENVI 4.8 se realizó la georreferenciación de las mismas utilizando como base la imagen del USGS. Para esto, se eligieron 20 puntos de control (GCP) con un error medio (RSM) de 0,5 píxeles. Se utilizó un polinomio de 1º grado para el ajuste de la imagen, utilizando el método de remuestreo de vecino más cercano.

---

### 3.2.3 ÍNDICES NORMALIZADOS DE VEGETACIÓN Y AGUA

---

Los datos recogidos por los satélites son procesados con el fin de producir estimaciones de variables ecológicas reales y aproximaciones a variables meteorológicas medidas “in situ” (Hay, 1998). Estas estimaciones no son más que transformaciones de imágenes usando algoritmos de bandas. Las mismas han sido muy usadas para monitorear cambios en factores naturales como ser las precipitaciones y la temperatura de la superficie. Analizar las imágenes satelitales disponibles hasta el momento puede proporcionar un contexto histórico-ecológico a partir del cual se puede establecer la relación entre los datos ambientales obtenidos de los satélites y la transmisión de enfermedades. Una vez establecida esta relación, la

obtención de imágenes satelitales en tiempo real para monitorear cambios ambientales puede ser utilizada como parte de un sistema de alerta temprana.

El cálculo de índices es una técnica de uso habitual en teledetección y son comúnmente utilizados para mejorar la discriminación entre cubiertas o elementos que presenten un comportamiento reflectivo muy distinto entre dos o más bandas, por ejemplo para realzar suelos y vegetación en el espectro visible e infrarrojo cercano, y para reducir el efecto del relieve (pendiente y orientación) en la caracterización espectral de distintas cubiertas. Numerosos índices pueden ser obtenidos a partir de algoritmos aplicados sobre bandas originales de sensores, como por ejemplo los índices de Agua (Normalized Difference Water Index: NDWI), Suelo (Normalized Difference Soil Index: NDSI) y Vegetación (Normalized Difference Vegetation Index: NDVI), o los índices Tasseled Cap, indicadores de verdor, brillo y humedad, o de Temperatura de Superficie (Land Surface Temperature (LST))(Rotela, 2013)

### 3.2.3.1 ÍNDICE NORMALIZADO DE VEGETACIÓN: NDVI

---

Para la identificación de masas vegetales, los cocientes o índices se basan en el particular comportamiento radiométrico de la vegetación. Una masa vegetal en óptimas condiciones, es decir en buen estado sanitario, posee una firma espectral que se caracteriza por un claro contraste entre la banda que corresponde al rojo (0.6 a 0.7  $\mu\text{m}$ ) y el infrarrojo cercano (0.7 a 1.1 $\mu\text{m}$ ). Esto se da debido a que la mayor parte de la radiación solar recibida por la planta en el espectro del visible, es absorbida por los pigmentos de las hojas, mientras que éstos apenas afectan a la radiación recibida en el infrarrojo cercano, por lo que se presenta un alto contraste entre una baja reflectividad en el visible y una alta reflectividad en el infrarrojo cercano. Por lo tanto este comportamiento permite separar con relativa facilidad, la vegetación sana de otras cubiertas. En particular el Índice Normalizado de Vegetación (Jensen, 1986) o NDVI transforma datos multiespectrales en una única banda o imagen única, según el siguiente algoritmo:

$$\text{NDVI} = \frac{\text{Infrarrojo Cercano} - \text{Rojo}}{\text{Infrarrojo Cercano} + \text{Rojo}}$$

Para el sensor TM y ETM+, de los satélites Landsat 5 y 7 respectivamente:

$$\text{NDVI} = \frac{\text{Banda 4} - \text{Banda 3}}{\text{Banda 4} + \text{Banda 3}}$$

Los valores resultantes del NDVI, como para el resto de los índices normalizados, varían entre -1 y +1, siendo mayor el vigor vegetal presente en la zona observada o en cada píxel, cuanto más cercano a 1 sea el valor del NDVI. En cuanto a la aplicación del NDVI en Epidemiología, el mismo ha sido ampliamente utilizado para realizar modelos espaciales y temporales a fin de determinar los hábitats favorables para el desarrollo del vector y lograr predecir la aparición de casos de Malaria (Hay et al., 1998; Adimi et al., 2010). Si bien no hay una relación directa causal entre el NDVI y las variables ambientales, ambos factores responden de manera similar, en dirección y magnitud, a cambios en las condiciones meteorológicas (Hay et al., 1998) y puede ser utilizado como una aproximación a factores climáticos y ambientales (Gaudart et al., 2009).

---

### 3.2.3.2 ÍNDICE NORMALIZADO DE AGUA: NDWI

Existen distintas versiones del índice normalizado de agua pero todas estas se consideran buen indicador del contenido de agua y de las condiciones de humedad de



la vegetación. Sus valores varían entre -1 y 1 presentando los cuerpos de agua valores positivos mientras que la vegetación y el suelo presentan valores cero o negativos.

**Gao** (1996) propuso un NDWI que se obtiene a partir de:

$$NDWI_{gao} = (\rho_{NIR} - \rho_{SWIR}) / (\rho_{NIR} + \rho_{SWIR})$$

Donde

$\rho_{NIR}$  = reflectancia de la banda del infrarrojo cercano ( 0,86  $\mu$ m)

$\rho_{SWIR}$  = reflectancia de la banda del infrarrojo medio (1,2–20,5  $\mu$ m).

Para Landsat 5 TM y 7 ETM+ esta fórmula queda expresada de la siguiente manera:

$$NDWI_{gao} = (\text{banda 4} - \text{banda 5}) / (\text{banda 4} + \text{banda 5})$$

McFeeters (1996) en cambio, propuso un NDWI que, a diferencia del de Gao, utiliza la banda correspondiente al verde, como lo muestra la siguiente fórmula:

$$NDWI_{McFeeters} = (\rho_{Green} - \rho_{NIR}) / (\rho_{Green} + \rho_{NIR}),$$

O para Landsat se puede expresar como:

$$NDWI_{McFeeters} = (\text{banda 3} - \text{banda 4}) / (\text{banda 3} + \text{banda 4})$$

Xu et al. (2006) crearon un NDWI Modificado al que nombraron MNDWI (por sus siglas en inglés, de “Modified NDWI”). Se trata del NDWI de McFeeters con el reemplazo de la banda del infrarrojo cercano ( $\rho_{NIR}$ ) por la banda correspondiente al infrarrojo medio ( $\rho_{SWIR}$ ). Este índice se representa de la siguiente manera:

$$MNDWI = (\rho_{Green} - \rho_{SWIR}) / (\rho_{Green} + \rho_{SWIR})$$

O para Landsat se puede expresar como:

$$\text{MNDWI} = (\text{banda } 3 - \text{banda } 5) / (\text{banda } 3 + \text{banda } 5)$$

El NDWI es un índice que en este trabajo será no sólo utilizado como una aproximación a las condiciones de humedad del ambiente y sino también como una variable predictiva relacionada a la aparición de casos de Malaria.

---

### 3.2.4. METODOLOGÍA PARA LA GENERACIÓN DE SERIES TEMPORALES DE NDVI, NDWI Y LST

---

Los pasos realizados para la obtención de las series temporales se detalla a continuación (Figura 15).

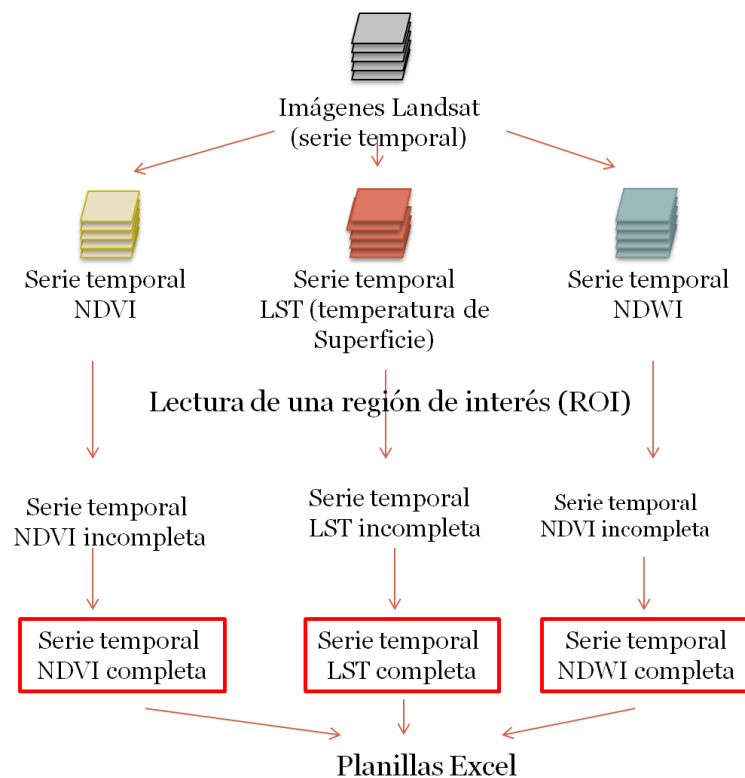


Figura 15. Pasos de procesamiento de las imágenes satelitales para la obtención de las series temporales.

De la serie de imágenes descargadas originalmente, se obtuvieron un total de tres series temporales: una de NDVI, una de NDWI y otra de LST. Para el procesamiento se utilizó ENVI 4.8 e IDL.

La siguiente descripción resume la serie de pasos de la Figura 15 (cada uno de los pasos descrito a continuación se realizó para cada una de las variables (NDVI, NDWI, LST)):

Utilizando la herramienta “*Layer Stacking*” de ENVI 4.8 se unió, en un solo archivo, todas las imágenes de la serie temporal a fin de manipular todas las bandas de una sola vez, ya que forman parte de un mismo archivo.

Luego se definió un área de interés (ROI) a partir de la cual se calcularon cuatro estadísticos (valor mínimo, media, valor máximo, varianza) para cada una de las series temporales. La ROI fue delimitada en una zona de Yungas (cobertura selvática) donde no hubo cambio de cobertura alguno durante el periodo de estudio. Se eligió esta zona como ROI porque cualquier cambio ocurrido en las variables medidas, sería producto del ambiente y no de modificaciones de origen antrópico. El área de interés definido fue de 57 x 57 píxeles (1,7 km de lado) y contuvo 3.249 píxeles (Figura 16).




Figura 16. El recuadro amarillo muestra el área de interés (ROI) del cual se extrajeron

El ROI fue transformado a un archivo vectorial tipo .shp para realizar con él un recorte del archivo de imágenes. El resultado fue un archivo con todas las imágenes (bandas) del tamaño de la ROI.

El siguiente paso fue calcular, a partir del archivo resultante, los cuatro estadísticos de las tres variables ambientales, es decir que por cada variable ambiental se obtuvieron cuatro estadísticos (Figura 17).

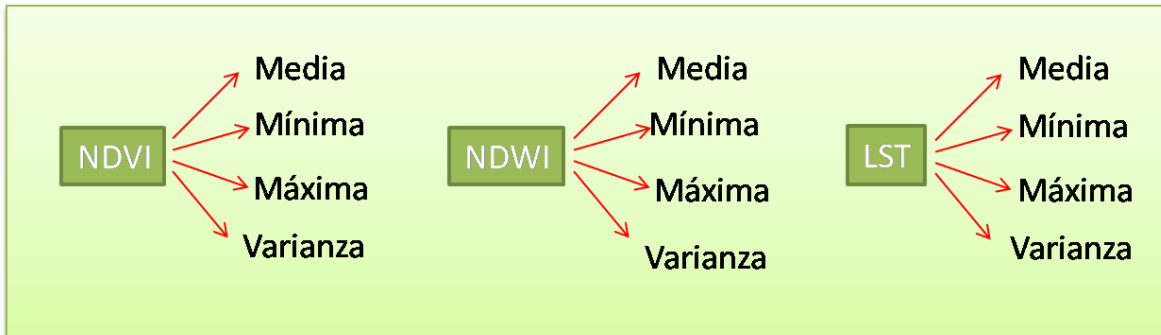


Figura 17. Esquema de las variables (media, valor mínimo, valor máximo y varianza) obtenidas de cada serie temporal (NDVI, NDWI, LST).

Para lograr esto se utilizó un script de IDL realizado por el Lic. Mario Lamfri. Este script es una serie de comandos cuya función es identificar el archivo a procesar, recorrer las bandas del mismo mediante *i* iteraciones e ir, mientras tanto, calculando los cuatro estadísticos.

Los datos de los meses faltantes fueron calculados con otro script en IDL en el cual se usó una función de interpolación llamada /INTERPOL. La misma calcula los datos faltantes a partir de una función lineal con los datos disponibles, como lo muestra el ejemplo para la serie de la media de NDVI (Figura 18).




Figura 18. Fluctuación temporal del NDVI medio para San Ramón de la Nueva Orán. El mes 0 corresponde a enero de 1986 y el mes 240 a diciembre de 2005.

---

# CAPÍTULO 4: MODELOS DE SERIES TEMPORALES ARIMA

---

## 4.1 INTRODUCCIÓN

---

Una serie temporal es el conjunto de observaciones de una variable, realizadas a intervalos regulares y de forma secuencial en el tiempo, en las que el orden de observación es importante. Una de las razones más importantes para llevar a cabo análisis de series temporales es intentar predecir los valores futuros de la serie. Conocer el comportamiento de la serie temporal en el pasado, nos permite mediante el ajuste de modelos temporales, realizar predicciones acerca de cómo será su comportamiento en el futuro. Identificar cuando sucederá un brote de alguna enfermedad es el primer paso hacia una intervención de control efectiva (Allard, 1998).

---

### 4.1.1 MODELOS ARIMA

---

El análisis temporal de Box-Jenkins o el modelo ARIMA modela los casos reportados permitiendo predecir números esperados de casos y provee intervalos de confianza en torno a estas predicciones. Comparar estas predicciones con los casos observados, facilita la toma de decisiones y permite determinar si un exceso de casos representa un brote de una enfermedad o una variación al azar.

La palabra ARIMA significa Modelos Autorregresivos Integrados de Medias Móviles.

Definimos un modelo como autorregresivo si la variable endógena de un período  $t$  es explicada por las observaciones de ella misma correspondientes a períodos anteriores añadiéndose un término de error. Un modelo de medias móviles es aquel que explica el valor de una determinada variable en un período  $t$  en función

de un término independiente y una sucesión de errores correspondientes a períodos precedentes, ponderados convenientemente.

Supongamos que...  $z_{t-1}$ ,  $z$ ,  $z_{t+1}$ ,... son observaciones (número de entradas a un hospital, la concentración de un contaminante, etc.) en los tiempos . . .  $t-1$ ,  $t$ ,  $t+1$ , ... . (Por ejemplo: ayer, hoy, mañana...). Supongamos que  $a_{t-1}$ ,  $a$ ,  $a_{t+1}$ ,... es una serie de ruido blanco, es decir, una variable aleatoria idénticamente distribuida con media cero y varianza  $\sigma_a^2$ .

Para comenzar, asumimos que la presente observación  $z$  es linealmente dependiente de la observación previa  $z_{t-1}$  y del ruido blanco  $a_t$ :

$$z = \phi z_{t-1} + a_t, \text{ donde } \phi \text{ es un parámetro}$$

Esta expresión se asemeja a una ecuación de regresión ordinaria.

Como  $z$ , es regresivo con respecto a  $z_{t-1}$ , se llama modelo autorregresivo de primer orden, abreviado como AR(1).

Alternativamente  $z$  puede expresarse como una combinación lineal del ruido blanco del presente y del momento previo:

$$z = a_t - \theta a_{t-1}, \text{ donde } \theta \text{ es un parámetro}$$

Esta expresión es llamada modelo de media móvil de primer orden, abreviada como MA(1).

Un modelo ARIMA incluye los dos términos (o parámetros) antes descriptos: "autorregresivo" (AR) y de "media móvil" (MA). Cada uno incluye un término que indica el número de *lags* (retrasos), designándose este término como "grado". Así, los términos autorregresivos relacionan la observación obtenida al tiempo  $t$  a la

observación obtenida al tiempo t-1 (primer grado), o a la obtenida al tiempo t-2 (segundo grado) y así sucesivamente. El término de media móvil relaciona el error (diferencia entre los valores observados y esperados) al tiempo t con el error al tiempo t-1, t-2, etc. Ambos sets pueden también incluir términos estacionales (de grado 12, 13, 52, etc., dependiendo del intervalo entre observaciones) y sus múltiplos (Allard, 1998).

El modelo autorregresivo de orden p (modelo AR(p)) se designa como:

$$z = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + a_t$$

y el modelo de media móvil de orden q (modelo MA(q)) como:

$$z = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Combinando los dos modelos anteriores obtenemos lo que se denomina modelo autorregresivo de media móvil de orden p y q (modelo ARMA (p,q)):

$$z = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + a_t + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Los modelos ARIMA también pueden ser expresados como: ARIMA(*p, d, q*)(*P, D, Q*), donde *p* es el orden de autorregresión, *d* el grado de diferenciación y *q* el orden de la media móvil. *P, D* y *Q* son los mismos órdenes anteriores pero para la componente estacional. La diferenciación es necesaria cuando la serie no es estacionaria (en media y varianza), es decir, cuando presenta tendencia. Un requerimiento de los modelos ARIMA es que las series sean estacionarias, es decir que no contengan tendencia y que la varianza se mantenga constante.



---

#### 4.1.2 MODELOS ARIMA MULTIVARIANTES: FUNCIÓN DE TRANSFERENCIA

---

Cuando se quiere conocer el efecto que tienen ciertas variables independientes (predictoras) sobre una variable dependiente, debemos relacionar ambas variables mediante la llamada Función de Transferencia (TF). La Figura 19 muestra un diagrama esquemático de la TF, la cual representa esta situación.

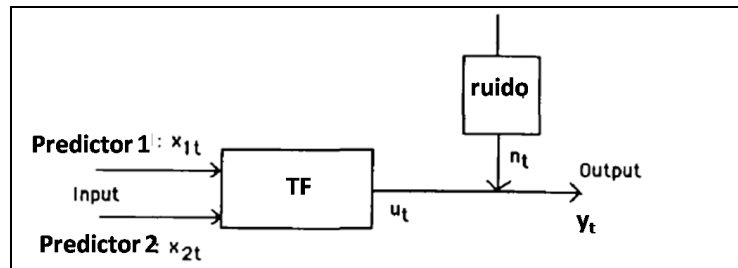


Figura 19. Representación esquemática de la Función de Transferencia con dos inputs (predictor 1 y predictor 2).

En la Figura 19,  $y_t, y_{t+1}, \dots$  son observaciones de la variable dependiente a los tiempos  $t, t+1, \dots$ . La serie de salida (output) y está compuesta por dos partes:

$$y_t = u_t + n_t$$

donde  $u_t$  es la variable de entrada  $x$  (variable independiente) y  $n_t$  es el error, el cual describe la parte de la variable  $y_t$  debida al azar.

Se asume que  $u_t$  está dado por la suma de pesos de valores presentes y valores pasados de  $x$ :

$$u_t = v_0 x_t + v_1 x_{t-1} + \dots$$

donde  $n_t$  es un proceso ARIMA descrito anteriormente.  $v_0, v_1$  son los llamados pesos de la TF.

La relación entre las variables independientes  $x$  y las dependientes  $y$ , está determinada por la función de correlación cruzada. Esta función determina la correlación existente entre ambas series en función de retrasos en el tiempo  $k$  y es la que determina los valores de los pesos de la TF (Helfenstein, 1991).

Cuando las observaciones corresponden a una única variable, el análisis de series temporales suele tener como objetivo construir un modelo para explicar la estructura (descripción) y prever la evolución (predicción) de la variable de interés. Cuando se observa simultáneamente un grupo de variables, el objetivo que se persigue consiste generalmente en analizar las posibles relaciones entre las variables observadas y su evolución conjunta. Este último punto debe ser tratado mediante técnicas multivariantes de análisis de series temporales.

El **objetivo principal** en este capítulo fue encontrar un modelo ARIMA capaz de predecir la aparición de casos de Malaria en San Ramón de la Nueva Orán utilizando, como variables predictoras, variables ambientales (NDVI, NDWI y LST) obtenidas de imágenes satelitales.

En este capítulo se describe a los modelos ARIMA y mediante el programa SPSS se ajusta automáticamente un modelo ARIMA multivariante a los datos de casos de enfermos de Malaria, con el fin de predecir la incidencia de la enfermedad.

---

## 4.2 MATERIALES Y MÉTODOS

---

Para establecer la relación entre la prevalencia de la Malaria y las variables ambientales obtenidas de las imágenes satelitales, se estimó un modelo ARIMA multivariante. Este modelo reflejó la influencia de los valores de las variables (dependientes) y el ruido aleatorio de las mismas en momentos del pasado reciente, sobre los valores de la variable dependiente en cada momento teniendo en cuenta el efecto de las variables independientes y sus respectivos retardos (Rua Uribe et al., 2013).

La búsqueda del modelo ARIMA con el mejor ajuste a los datos, se estimó usando la opción “Modelador Experto” del módulo de Series Temporales del software SPSS 15.0. Para esto, las series de casos de Malaria y de variables ambientales fueron

divididas en dos sub-periodos: un sub-**período de estimación**, que es usado para determinar cuál es el modelo que mejor se ajustó a los datos y un **período de predicción**, que se usó para verificar la capacidad de pronóstico del modelo. El periodo de estimación comprendió desde enero de 1986 a diciembre de 1999, dejándose como periodo de predicción a los datos correspondientes al año 2000 (desde enero a diciembre de dicho año).

El Modelizador Experto busca automáticamente el modelo que mejor se ajusta a cada serie dependiente. Si se especifican variables independientes (predictoras), el Modelizador Experto selecciona para su inclusión en los modelos ARIMA, las que tienen una relación estadísticamente significativa con la serie dependiente. Si ninguna de las variables independientes disponibles aporta información, muestra un modelo ARIMA univariante. Las variables del modelo se transforman cuando es necesario, mediante una diferenciación y/o una raíz cuadrada o una transformación logarítmica natural (Loha and Lindtjørn, 2010).

El software SPSS 15.0 permite definir funciones de transferencia para algunas o todas las variables independientes especificadas. Las funciones de transferencia permiten especificar el modo en que se utilizan los valores anteriores de las variables independientes (predictoras) para predecir valores futuros de la serie dependiente. La TF está compuesta por distintos órdenes para un Numerador, un Denominador y una Diferencia, a los cuales se les debe asignar un número entero positivo.

**Numerador:** Es el orden de numerador de la función de transferencia. Especifica los valores previos de la serie independiente (predictora) seleccionada que se utiliza para predecir los valores actuales de la serie dependiente. Por ejemplo, un orden de numerador de 1 especifica que se utiliza el valor de una serie independiente de un período anterior (además del valor actual de la serie independiente) para predecir el valor actual de cada serie dependiente.

**Denominador.** Es el orden de denominador de la función de transferencia. Especifica cómo se utilizan las desviaciones de la media de la serie para los valores previos de la serie independiente (predictora) seleccionada para predecir los valores actuales de la serie dependiente. Por ejemplo, un orden de denominador de 1 especifica que las desviaciones del valor medio de una serie independiente para un

período de tiempo anterior se tienen en cuenta al predecir el valor actual de cada serie dependiente.

**Diferencia.** Especifica el orden de diferenciación aplicado a la serie independiente (predictora) seleccionada antes de estimar los modelos. La diferenciación es necesaria si hay tendencias y se utiliza para eliminar su efecto.

---

#### 4.2.1 AJUSTE DEL MODELO

---

Para determinar el nivel de ajuste del modelo ARIMA multivariante propuesto por el Modelador Experto, se usó el coeficiente de determinación ( $R^2$ ) que determina la proporción de la varianza de la variable dependiente explicada por el modelo. Este valor estadístico puede variar entre 0 y 100 %. El ajuste del modelo se testeó además con un análisis de los residuos, para lo cual se verificó que los mismos no estuviesen correlacionados. Esto se testeó mediante el cálculo del índice Q de Ljung-Box, el cual es un test estadístico que prueba si un existe autocorrelación entre los residuos (un índice Q no significativo indica que los residuos no están correlacionados).

---

#### 4.3 RESULTADOS

---

El modelo propuesto por el Modelador Experto para la predicción de los casos de Malaria a partir de las variables ambientales NDVI, NDWI y LST extraídos de imágenes satelitales, se muestra en la Tabla 5:

			Tipo de modelo
ID del modelo	casos	Modelo_1	ARIMA(0,0,1)(0,0,0)

Tabla 5. Modelo ARIMA propuesto por el Modelador Experto.

Corresponde a un modelo ARIMA(0,0,1)(0,0,0). Esto significa que las variables ingresadas no necesitaron ningún tipo de diferenciación, ya que de haberlo hecho el modelo hubiese incluido estos pasos de manera automática. Un modelo ARIMA de este tipo es equivalente a un modelo de media móvil MA(1), en donde los casos que ocurren en un determinado mes, dependen del error correspondiente al mes anterior.

El Modelador Experto fue configurado para buscar el mejor modelo ARIMA teniendo en cuenta a las 12 variables ambientales obtenidas de las imágenes satelitales como variables predictoras. El mismo encontró que fueron dos las variables predictoras (“número de predictores”) significativas. El coeficiente de determinación fue 0,882 lo que significa que el 88 % de la variabilidad observada puede explicarse por el modelo (Tabla 6). La validez del modelo desarrollado fue confirmada mediante la visualización de los residuos, sin detectarse autocorrelación para ningún retardo. Esto fue corroborado con la prueba de Ljung-Box, la cual no fue significativa ( $p = 0,420$ ) (Tabla 6).

Modelo	Número de predictores	Estadísticos de ajuste del modelo			Ljung-Box Q(18)			Número de valores atípicos
		R-cuadrado estacionaria	R-cuadrado	RMSE	Estadísticos	GL	Sig.	
casos-Modelo_1	2	.882	.882	1,856	17,511	17	.420	9

Tabla 6. Detalles de los parámetros del modelo propuesto por el Modelador Experto.

Se observó que el NDVI máximo y el NDWI medio fueron las únicas variables ambientales que influyeron en la aparición de casos de Malaria en San Ramón de la Nueva Orán (Tabla 7).

					Estimación	ET	t	Sig.
casos-Modelo_1	casos	Sin transformación	MA	Retardo 1	-.280	.081	-3,473	.001
	NDVI_max	Sin transformación	Numerador	Retardo 0	4,368	.453	9,639	.000
	NDWI_media	Sin transformación	Retardo		5			
			Numerador	Retardo 0	-4,588	.963	-4,764	.000

Tabla 7. Estimadores de la TF propuestos por el Modelador Experto.

También se observó que los efectos del NDWI medio no serían inmediatos sino se observarían aproximadamente después de 5 meses (Tabla 7).

La Figura 20 muestra la fluctuación de los casos de Malaria durante el período comprendido entre enero de 1986 hasta diciembre de 2000 (línea roja). Se observa además el ajuste del modelo propuesto (línea azul), los intervalos de confianza inferior y superior (líneas de puntos) y la fluctuación de casos propuesta por el modelo para el año 2000 (en verde).




Figura 20. Ajuste del modelo ARIMA (0,0,1)(0,0,0) y predicción para los casos de Malaria en San Ramón de la Nueva Orán, desde 1986 a 2000.

En esta Figura se observa que el modelo ARIMA (0,0,1) mostró un buen ajuste con respecto a los casos de malaria durante el periodo de estimación, así como también fue capaz de predecir de manera adecuada los casos de Malaria ocurridos en el periodo de predicción (año 2000).

---

## CAPÍTULO 5: INFLUENCIA DE LAS VARIABLES AMBIENTALES SOBRE LOS CASOS DE MALARIA

---

El objetivo de este capítulo fue analizar el grado de influencia que tienen las variables climáticas y/o ambientales (NDVI, NDWI y LST) obtenidas de sensores remotos sobre la aparición de casos de Malaria en San Ramón de la Nueva durante el periodo comprendido entre enero de 1986 a diciembre de 2005.

---

### 5.1 MATERIALES Y MÉTODOS

---

En primera instancia se llevó a cabo un análisis de correlación entre las variables ambientales obtenidas de los satélites y así evitar problemas de multicolinealidad (alta correlación entre las variables explicativas) (Tabla 8). Posteriormente, se hizo una selección de las mismas y se consideró dos modelos posibles: un Modelo A que incluyó las variables NDVImed, NDWivar, LSTmed y LSTvar. Y un Modelo B que incluyó las variables NDWImed, NDVivar, LSTmed, LSTvar.

	NDVImin	NDVImedia	NDVImax	NDVIvar	NDWImin	Wimedia	NDWImax	NDWIvar	LSTmin	LSTmedia	LSTmax
NDVImin	1										
NDVImedia	0.865	1.000									
NDVImax	0.759	0.958	1.000								
NDVIvar	-0.434	-0.250	-0.110	1.000							
NDWImin	0.823	0.768	0.665	-0.503	1.000						
Wimedia	0.779	0.905	0.862	-0.309	0.876	1.000					
NDWImax	0.582	0.807	0.828	-0.189	0.770	0.932	1.000				
NDWIvar	-0.419	-0.141	0.081	0.194	-0.247	-0.051	0.171	1.000			
LSTmin	0.128	0.072	0.032	-0.019	0.055	0.057	0.010	-0.085	1.000		
LSTmedia	-0.010	-0.026	-0.056	0.058	-0.042	-0.042	-0.049	-0.029	0.961	1.000	
LSTmax	-0.093	-0.095	-0.110	0.123	-0.128	-0.115	-0.110	0.006	0.932	0.989	1.000
LSTVar	-0.544	-0.409	-0.317	0.410	-0.453	-0.411	-0.269	0.304	-0.185	0.064	0.156

Tabla 8. Análisis de correlación entre las variables ambientales NDVI, NDWI y LST.



Antes de aplicar el análisis estadístico a los Modelos A y B, se llevó a cabo un análisis exploratorio de los datos con el fin de observar si había una correlación entre el número de casos de Malaria y las variables independientes. Como resultado se observó que los números de casos de enfermos aumentaban si se consideraba a las variables independientes medias con un *lag* de un mes (Figura 21).

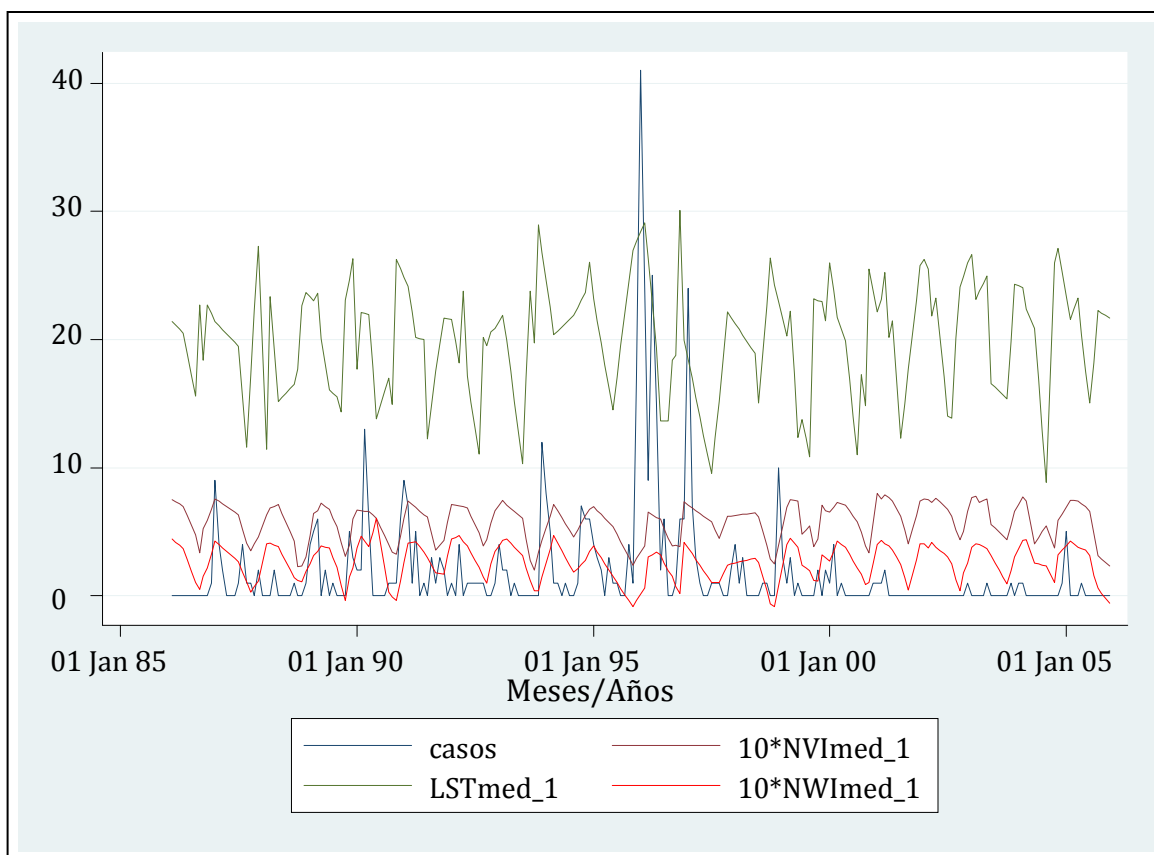


FIGURA 21. FLUCTUACIÓN DE CASOS DE MALARIA, NDVI MEDIA, NDWI MEDIA Y LST MEDIA (PARA AJUSTAR LA ESCALA SE CONSIDERÓ A NDVIMED Y NDWIMED MULTIPLICADA POR 10).

Por su parte, a través de un análisis de la media y de la varianza de las variables independientes consideradas por cada año, se observó que el promedio de casos de Malaria presentaba una gran variabilidad por año y que la media y la varianza del número total de casos en los 20 años era muy diferente (Anexo B).

Este resultado llevó a que se considere aplicar modelos de regresión Poisson con sobredispersión de datos y con un parámetro  $\lambda$  (tasa de incidencia) variable por año, es decir  $\lambda$  variable con el tiempo (no es constante).

Resumiendo, la fluctuación de las variables climáticas/ambientales en relación con la aparición de los casos de Malaria fue analizada mediante regresiones de Poisson.

Para una única variable independiente  $X$ :

$$\ln(\lambda | X = x) = \alpha_0 + \alpha_1 X$$

o, para simplificar la notación, simplemente:

$$\ln \lambda = \alpha_0 + \alpha_1 X$$

donde  $\ln$  significa logaritmo neperiano,  $\alpha_0$  y  $\alpha_1$  son constantes y  $X$  una variable que puede ser aleatoria o no, continua o discreta. Este modelo se puede fácilmente generalizar para  $k$  variables independientes:

$$\ln \lambda = \alpha_0 + \alpha_1 X_1 + \dots + \alpha_k X_k$$

Por lo tanto  $\alpha$  es el logaritmo de  $\lambda$  (probabilidad de que ocurra un evento en un intervalo de tamaño unidad) cuando todas las variables independientes son cero, y  $\alpha_i$  es el cambio en el logaritmo de  $\lambda$  (o logaritmo del cociente de  $\lambda$ ) cuando la variable  $X_i$  aumenta una unidad, manteniéndose constantes las demás o, dicho de otro modo,  $e^{\alpha_0}$  es la probabilidad de que ocurra un evento en un intervalo unidad cuando todas las variables independientes son cero y  $e^{\alpha_i}$   $\lambda$  el cociente de dicha probabilidad para un aumento de una unidad en la variable  $X_i$  (riesgo relativo). Obsérvese que, al igual que en la regresión logística, el modelo supone efectos multiplicativos, es decir, si la

variable  $X_i$  aumenta  $n$  unidades, la probabilidad para la variable Poisson se multiplica por  $e^{n\alpha_i} = (e^{\alpha_i})^n$  es decir, la potencia  $n$ -ésima de  $e^{\alpha_i}$ .

Teniendo en cuenta, que para una variable Poisson:  $\mu = \lambda\sigma$  el modelo también se puede poner en función de  $\mu$  como:

$$\ln \mu = \ln s + \alpha_0 + \alpha_1 X_1 + \dots + \alpha_k X_k$$

Como resultado se obtiene un índice denominado Razón de la Tasa de Incidencia o Incidence Rate Ratio (*IRR*). A través de este índice es posible determinar el porcentaje de influencia de cada una de las variables climáticas/ambientales sobre la aparición de casos de Malaria. A su vez, se obtienen también valores de error estándar (*E. E.*),  $p$  y de los intervalos de confianza (*I. C.* 95 %).

Así es como para el presente trabajo se analizaron los datos mediante dichas regresiones Poisson pero considerando los dos modelos anteriormente citados, un Modelo A que incluyó las variables NDVImed, NDWlvar, LSTmed y LSTvar. Y un Modelo B que incluyó las variables NDWlmed, NDVIvar, LSTmed, LSTvar.

## 5.2 RESULTADOS

---

De acuerdo a las variables incluidas en el Modelo A (NDVImed, NDWlvar, LSTmed y LSTvar), se observó que sólo resultaron significativas el NDVImed y la LSTmed ( $p= 0,001$  y  $p= 0,016$  respectivamente) (Tabla 9).

Variable	coeficiente	<i>IRR</i>	<i>E. E.</i>	$p$	<i>I. C.</i> 95 %
NDVI media	-3.343294	0.035320	0.927147	0.001	(0.006,0.219)
LST media	0.101873	1.107243	0.041824	0.016	(1.020,1.202)

Tabla 9. Estimadores del Modelo A. *IRR*: Razón de la Tasa de Incidencia, *E. E.*: Error Estándar; *I.C. 95 %*: Intervalo de Confianza.

Con el Modelo A se predice que:

- a) por cada 0.1 unidades que aumenta el NDVImed con respecto al NDVImed promedio de los 20 años (0.57318), el *IRR* disminuye un 29 % (en 0.71) respecto la tasa de incidencia que se produce cuando NDVImed y LSTmed toman el valor promedio de los 20 años (0.57318 y 19.9089, respectivamente).
  
- b) Por cada unidad de cambio en LSTmed con respecto a la LSTmed promedio de los 20 años (19.9089), el *IRR* cambia en 1,107 (aumenta un 11%) respecto de la tasa de incidencia que se produce cuando NDVImed y LSTmed toman el valor promedio de los 20 años (0.57318 y 19.9089, respectivamente).

Es así como en la Figura 22 se observa la relación de los casos de Malaria con la variabilidad observada para el NDVI medio y para el LST medio.




Figura 22. Relación entre casos de Malaria y la variabilidad del NDVI medio y del LST medio.

De acuerdo a las variables incluidas en el Modelo B (NDWImed, NDVIvar, LSTmed, LSTvar) se observó que sólo resultaron significativas el NDWImed y la LSTmed ( $p= 0,005$  y  $p= 0,013$  respectivamente). (Tabla 10).

Variables	coeficiente	<i>IRR</i>	<i>E. E.</i>	<i>p</i>	<i>I. C. 95 %</i>
NDWI media	-2.926246	0.053598	0.999834	0.005	(0.006,0.318)
LST media	0.106513	1.112393	0.037246	0.013	(1.034,1.198)

Tabla 10. Estimadores del Modelo B. *IRR*: Razón de la Tasa de Incidencia, *E. E.*: Error Estándar; *I.C. 95 %*: Intervalo de Confianza.

De acuerdo a este Modelo se predice que:

- a) por cada 0.1 unidades que aumenta el NDWImed con respecto a la NDWImed promedio de los 20 años (0.25908), el *IRR* disminuye un 25 % respecto la tasa de incidencia que se produce cuando NDWImed y LSTmed toman el valor promedio de los 20 años (0. 25908 y 19.9089, respectivamente).
- b) Por cada unidad de cambio en LSTmed con respecto al LSTmed promedio de los 20 años (19.9089), el *IRR* aumenta un 11 % respecto de la tasa de incidencia que se produce cuando NWImed y LSTmed toman el valor promedio de los 20 años (0. 25908 y 19.9089, respectivamente).

Es así como en la Figura 23 se observa la relación de los casos de Malaria con la variabilidad observada para el NDWI medio y para el LST medio.




Figura 23. Relación entre casos de Malaria y la variabilidad del NDVI medio y del LST medio.

Ambos modelos (A y B) mostraron resultados muy semejantes, ya que el efecto humedad y vegetación es similar, aunque el modelo A presentó una mayor confiabilidad.

---

## CAPÍTULO 6: DISCUSIÓN Y CONCLUSIONES

---

### 6.1 DISCUSIÓN

---

Epidemiológicamente, el noroeste de Argentina fue una región importante en vista de la serie de brotes de casos de Malaria que se inició a finales del siglo '19 (Mühlens et al., 1925; Dantur Juri et al., 2009).

El desarrollo de la enfermedad en el noroeste del país ha estado siempre influenciado por la topografía, el clima y la fitogeografía (Bejarano, 1959a). Así, la llamada “área malárica montañosa” podía estar claramente definida en las provincias del norte y del centro de la Argentina (Bejarano, 1959a, 1959b; Martínez-Palomo, 1991). La temporada de transmisión de la enfermedad se iniciaba en octubre o noviembre en Salta y Jujuy, en noviembre o diciembre en Tucumán, Santiago del Estero y Catamarca, y en diciembre y enero en La Rioja y Córdoba, pudiendo retrasarse si el invierno anterior había sido muy frío o si la primavera anterior muy lluviosa. La transmisión de la Malaria podía durar hasta mayo o junio para toda el área, y prolongarse durante inviernos suaves (Bejarano, 1959a; Mühlens et al., 1925; Dantur Juri et al., 2009).

En el presente trabajo, la **fluctuación** de casos de Malaria observada en San Ramón de Orán la Orán, para el período 1986-2005, mostró un **patrón estacional** con picos de mayor abundancia para los meses de verano y de otoño. Esto coincide con lo reportado por Dantur Juri et al. (2009) quienes encontraron para la localidad de Aguas Blancas (en la frontera con Bolivia) que los casos de Malaria aparecían durante el verano y el otoño siendo precedidos tres meses antes por la mayor abundancia del mosquito vector, *An. pseudopunctipennis*. Así, la aparición de los casos de Malaria estarían relacionados directamente no sólo con la presencia sino también con los períodos de mayor abundancia del mosquito vector que para el área de estudio fueron reportados en la primavera (Dantur Juri et al., 2003, 2010a) así como también para el verano (Dantur Juri et al., 2009).

En base al análisis descriptivo se observó que la mayor cantidad de casos de Malaria en San Ramón de la Nueva Orán correspondieron al sexo masculino, entre los 15-30 años de edad principalmente y cuya actividad laboral estuvo relacionada a tareas rurales (agricultura, ganadería, extracción forestal, pesca, etc.).

Es sabido que la dinámica de la Malaria se encuentra relacionada a actividades humanas como ser la deforestación, agricultura e irrigación, migración y transporte, urbanización, construcción de caminos y represas, etc. (Patz et. al., 2004,). San Ramón de la Nueva Orán se encuentra ubicada en el pedemonte de las Yungas, zona que ha sufrido profundas transformaciones antrópicas durante las últimas décadas, principalmente por la deforestación para generar tierras para la actividad agrícola o bien para la urbanización. Esto último trae aparejado la migración de la población hacia zonas rurales en busca de trabajo, y es allí cuando las personas susceptibles comienzan a tener mayor contacto con poblaciones de mosquitos. Esto se debe a que aumenta los parches de vegetación natural, los cuales están en contacto con las áreas de cultivo y representan zonas donde la abundancia de mosquitos es alta (Dantur Juri et. al., 2005). Hay que tener en cuenta además que la generación de tierras agrícolas genera condiciones propicias para la formación de criaderos, como ser por ejemplo canales de riego. Esto aumenta las poblaciones de mosquitos, aumentando la probabilidad de contraer a la enfermedad por parte de los trabajadores rurales, quienes además, en general, no usan vestimenta que los cubra durante las horas de trabajo ni repelentes.

En el trabajo se observó que el grupo etario más afectado fue el comprendido por personas de 15 a 30 años de edad, seguidos por los 31 a 45 años de edad. Esto tiene sentido, ya que son los adultos jóvenes quienes generalmente llevan a cabo los trabajos rurales, mientras que las mujeres y los niños permanecen en el domicilio. En San Ramón de la Nueva Orán, se pudo observar que la mayoría de las personas infectadas fueron jornaleros, es decir peones de campo. Esto concuerda con un trabajo llevado a cabo por Sanabria et al. (2004) en Perú, en donde encuestaron a personas que habían contraído la enfermedad. Todas ellas fueron personas del sexo masculino dedicadas a tareas de campo. Notaron además que ninguna de ellas se protegió durante la actividad laboral (ya sea con ropa adecuada o mediante el uso de



repelentes). Dantur Juri et al. (2009) analizaron el porcentaje de enfermos de Malaria en cuanto al sexo en El Oculito y Aguas Blancas (departamento Orán) y encontraron una alta prevalencia de casos del sexo masculino (79%) para El Oculito en comparación con Aguas Blancas (47%). Los autores consideraron que esta diferencia tan marcada fue debido a que Aguas Blancas es una ciudad que se encuentra en la frontera con Bolivia por lo que la actividad principal es el comercio, y no las actividades agrícolas, estando las mujeres también implicadas en esta actividad.

Lo expuesto anteriormente debería ser tenido en cuenta por las autoridades de salud al momento de implementar medidas de control y así, estar prevenidos para la aparición de posibles casos de enfermos, ya que al conocer cuáles son las estaciones climáticas con mayor cantidad de casos reportados, se puede deducir que puede existir una mayor exposición y contagio de la enfermedad. Es importante además alertar a la población susceptible (trabajadores rurales y todo aquel que realice actividades en la zona agrícola) para que tomen las medidas necesarias y así evitar contraer la enfermedad, evitando el contacto con el mosquito vector. Algunas medidas podrían incluir: utilizar vestimenta que cubra todo el cuerpo para evitar picaduras de mosquitos, utilizar repelentes, evitar exponerse en los horarios de máxima actividad del vector, etc.

A su vez, en este trabajo de tesis se buscó utilizar información ambiental obtenida de imágenes satelitales para predecir casos de Malaria y detectar factores ambientales que estén relacionados con la transmisión de la enfermedad. Se ha demostrado en otros trabajos, como los satélites pueden aportar información ambiental valiosa para estudios relacionados con la transmisión de diversas enfermedades. En Argentina, el uso de satélites para la observación de la Tierra es una disciplina científica que fue tomando gran importancia durante la última década. Para la realización de esta tesis, se generó una importante serie de imágenes Landsat 5 TM y 7 ETM con aproximadamente 150 imágenes, en las que se calcularon diferentes índices como el NDVI, el NDWI y la LST, brindando por ende información ambiental desde 1986 a 2005 del departamento de Orán así como también del departamento San Martín. Cabe destacar que esta es una zona endémica para la transmisión

vectorial de diversas enfermedades tales como el Hantavirus, la Leishmaniasis y el Dengue. Contar con esta serie temporal de imágenes, es de gran utilidad para llevar a cabo estudios que relacionen el ambiente con la transmisión de dichas enfermedades, y así aportar información útil a las autoridades de salud encargadas realizar monitoreos y prevención de estas enfermedades.

Así a partir de los diferentes índices obtenidos de las imágenes satelitales se procedió por un lado, a llevar a cabo modelos de series temporales ARIMA a fin de predecir la aparición de nuevos casos de Malaria y estimar el riesgo de transmisión de la enfermedad, y por otro lado, mediante análisis de regresiones de Poisson estudiar el grado de influencia de dichos índices y de variables climáticas sobre la aparición de casos de Malaria en San Ramón de la Nueva Orán.

Los modelos ARIMA han sido ampliamente usados en numerosas investigaciones, las cuales han establecido relaciones entre variables climáticas y factores asociados a la aparición de distintas enfermedades. Así, Loha & Lindtjørn (2010) analizaron la relación entre ciertas variables climáticas y la incidencia de Malaria en 42 localidades del sur de Etiopía, mediante el uso de modelos ARIMA multivariados. Encontraron que sólo para 7 localidades, las variables climáticas fueron significativas y que el término autorregresivo AR fue mucho más importante para la predicción de los casos de Malaria que las variables meteorológicas. Sin embargo, afirmaron que los modelos ARIMA son de utilidad al momento de predecir la incidencia de la enfermedad en Etiopía. En otro trabajo realizado por Wu et al. (2007) en sur de Taiwán, se evaluó el impacto de la variabilidad climática en la ocurrencia de casos de Dengue. Utilizando modelos ARIMA, los autores encontraron que la aparición de casos de Dengue estuvo asociada negativamente con la temperatura mensual y la humedad relativa mensual con un retraso de un mes. En América, Luz et al. (2008) utilizaron los modelos ARIMA para predecir la incidencia del Dengue en Río de Janeiro (Brasil). Encontraron que el número de casos de enfermos en un mes puede ser estimado teniendo en cuenta el número de casos de Dengue ocurridos uno, dos y doce meses anteriores. Los autores compararon el modelo ARIMA con un modelo ARIMA multivariante agregándole al mismo, variables climáticas como regresores externos.

Los autores encontraron que las predicciones realizadas con este último modelo no fueron significativamente mejores que las realizadas con el modelo ARIMA univariante. Aun así, concluyeron que los modelos ARIMA fueron capaces de predecir temporalmente la incidencia del Dengue en Río de Janeiro. En Colombia, Rúa-Uribe et al. (2010) modelaron el efecto de la variabilidad climática local sobre la transmisión del Dengue en Medellín mediante el ajuste de modelos ARIMA multivariantes. Los autores encontraron de que la transmisión del Dengue se vio afectada principalmente por la precipitación con un atraso de aproximadamente 20 semanas. Wangdi et al. (2010) realizaron un trabajo mediante el cual desarrollaron un modelo de predicción de incidencia endémica de Malaria en distintos distritos de Bhutan usando modelos ARIMA en conjunto con variables ambientales como predictoras. Los modelos ARIMA obtenidos mostraron variaciones para los distintos distritos, pero los autores concluyeron que en general, la temperatura y los casos ocurridos en el mes previo fueron los factores más importantes y los modelos ARIMA multivariantes fueron de gran utilidad a la hora de predecir la incidencia de la enfermedad en Bhutan.

En el presente trabajo se generó de manera automática un modelo ARIMA que se ajustó a los cambios en el comportamiento epidemiológico de la Malaria en San Ramón de la Nueva Orán. A partir de los índices NDVI, NDWI y LST utilizados como variables predictivas de la ocurrencia de casos, se observó que la prevalencia de los mismos estuvo relacionada con la aparición de casos en el mes anterior así como con el NDVI máximo y el NDWI medio observado 5 meses antes.

La relación entre el NDVI máximo y la prevalencia de la Malaria fue reportada anteriormente por Ahmadian Marj et al. (2010), los cuáles encontraron que la cobertura vegetal afecta directamente a la abundancia de los mosquitos anofelinos ya que mantiene la humedad del aire y del suelo, brindándoles además refugio (Dantur Juri, 2009). Otro estudio que concuerda con los resultados reportados fue el Hay et al. (1998) llevado a cabo en Kenia. En el mismo se observó que el número mensual de casos de Malaria estuvo fuertemente correlacionado con el NDVI del mes anterior. A su vez, observaron que un valor mínimo del NDVI fue necesario para que al mes siguiente se registraran más del 5 % del total de los casos anuales de Malaria. En otro

trabajo llevado a cabo en Burundi (África), Gómez Elipe et al. (2007) desarrollaron un modelo para predecir la incidencia de la Malaria a partir de la asociación entre las variables climáticas y el NDVI con los casos de Malaria notificados mensualmente. El mejor modelo que predijo la incidencia de la enfermedad incluyó a las precipitaciones, a la temperatura máxima y al NDVI del mes anterior. A su vez, Adimi et al. (2010) mediante el uso de registros de casos mensuales de Malaria de 23 provincias de Afganistán y su relación con variables ambientales como la precipitación, la temperatura y el NDVI, encontraron que este último, resultó ser el mejor predictor de la incidencia malárica en estas provincias de Afganistán. Resultados similares fueron reportados por Gaudart et al. (2009) en un trabajo realizado en Mali, África. En el mismo, establecieron una cohorte de niños de hasta 12 años que fue seguida durante cinco años evaluando en la misma la parasitemia de muestras de sangre. Mediante un análisis de series temporales entre la incidencia de *P. falciparum* y el NDVI encontraron que este índice explicaba el patrón estacional del parásito con una demora de 15 días y que un aumento en el NDVI producía un incremento significativo en la parasitemia.

Como se citó anteriormente, en este trabajo se observó que el NDWI se relacionó de manera inversa con la aparición de casos de Malaria en San Ramón de la Nueva Orán. El uso del NDWI como variable regresora en modelos temporales y espaciales de distintas enfermedades, ha sido reportado con anterioridad por algunos autores. Así por ejemplo está el trabajo de Estallo et al. (2011) en cual se demostró que el NDWI es un buen predictor de un índice entomológico relacionado con el Dengue (índice de Infección de Vivienda, HI) en San Ramón de la Nueva Orán. A su vez, Cohen et al. (2013) utilizaron el NDWI, entre otras variables ambientales de sensores remotos, con el fin de realizar modelos espaciales de la transmisión de Malaria en Suazilndia, África. Los autores mostraron como la transmisión de la enfermedad estaba relacionada a zonas que presentaron altos valores de NDWI. En una revisión realizada por Zhang et al. (2013) analizaron el uso de sensores remotos en relación al control de enfermedades en China. Los autores hicieron mención de cómo el NDWI fue utilizado para detectar potenciales hábitats de caracoles transmisores de

esquistosomiasis utilizando un modelo espacial y, afirmaron que el modelo mejoró significativamente al aumentar el NDWI al paquete de variables ambientales predictivas. En el trabajo de Dambach et al. (2012), los autores mostraron la existencia de una correlación significativa entre el NDWI y la presencia de criaderos del vector de la Malaria en una zona rural de Burkina Faso, lo que resultó de suma importancia para la generación de mapas de riesgo de transmisión de la enfermedad. Por su parte, Rosa et al. (2014) en un trabajo llevado a cabo en el norte de Italia, analizaron series temporales de capturas de *Culex pipiens*, mosquito vector del virus del Nilo Occidental, y de variables ambientales como ser la precipitación, temperatura y NDWI. Encontraron que un aumento del NDWI al comienzo del año estaba relacionado a un acortamiento de la estación de mayor abundancia de mosquitos.

Se puede decir que estos trabajos coinciden con lo reportado por Estallo et al. (2011) y Machault et al. (2011). El NDWI es un índice utilizado para la caracterización del ambiente ya que mide el contenido foliar de agua en la vegetación y constituye, además, una medida indirecta de la humedad del suelo y de las precipitaciones, las cuales juegan un papel muy importante en la biología del mosquito.

Si bien en estos trabajos la relación entre el NDWI y los factores causantes de la aparición de diversas enfermedades es positiva, en este trabajo el NDWI tiene un efecto negativo sobre la aparición de los casos de Malaria 5 meses después. Teniendo en cuenta que el NDWI es un índice que se encuentra relacionado con la ocurrencia precipitaciones y con las condiciones de humedad, la relación inversa entre el NDWI y la aparición de casos de Malaria podría estar explicada por la ocurrencia de fuertes precipitaciones, lo que produciría el lavado de los criaderos de las formas inmaduras de los mosquitos vectores con la consiguiente disminución de la población de adultos anofelinos, e indirectamente una disminución en el número de casos de enfermos de Malaria (Dantur Juri et al., 2009, 2010). Por otro lado Rosa et al. (2014) encontraron que un aumento de las precipitaciones al comienzo del año, llevó a un retraso en el comienzo de estación de abundancia del mosquito vector transmisor del virus del Nilo Occidental, el *Cx pipiens*, en el norte de Italia.

En diversos estudios se reportó que el NDWI tiene un efecto tardío sobre la aparición de casos de diferentes enfermedades transmitidas por mosquitos. Esto es esperable ya que es necesario tener en cuenta la dinámica de las enfermedades. En trabajos llevados a cabo en diferentes partes del mundo, se reportó un aumento de los casos de Malaria debido a las precipitaciones ocurridas 2 o 3 meses antes. En este trabajo se encontró que los casos de Malaria en San Ramón de la Nueva Orán estuvieron relacionados con una disminución en el NDWI registrado 5 meses antes. Rúa Uribe et al. (2010), en un trabajo realizado en Colombia, reportaron un resultado similar. En su trabajo, expusieron que la transmisión del Dengue en Medellín se encontró asociada con la variabilidad en las condiciones climáticas locales, en particular, con un retardo de 20 semanas en la precipitación (aproximadamente 5 meses). Según los autores, una de las hipótesis que podría explicar este retardo, considera que las poblaciones locales del vector se conectarían mediante la dispersión de un pequeño grupo de hembras migrantes que colonizarían nuevos hábitats (depósitos de agua) recién establecidos en la época de mayor pluviosidad. Posteriormente, al generarse varias poblaciones del vector, se favorecería el flujo de individuos entre los nuevos hábitats y, por lo tanto, la persistencia de las poblaciones de vectores a largo plazo. Esto generaría una densidad crítica de la población del vector que permitiría la eficiente dispersión del virus del Dengue entre la población humana.

Como resultado de las regresiones multinivel de Poisson, a partir de dos modelos planteados, se observó que los casos de Malaria podían aumentar cuando además de disminuir el NDVI medio, aumentaba la LST media; o bien cuando disminuía el NDWI y aumentaba la LST media. Es decir, para ambos modelos planteados, los casos de Malaria están relacionados positivamente a un aumento en la LST media. Es conocido que la temperatura es un factor clave en la transmisión de la Malaria (Martens et al., 1995).

Patz et al. (2000), López Vélez & Molina Moreno (2005), Sáez-Sáez et al. (2007) y Ahmadian Marj et al. (2008), reportaron que un aumento de la temperatura produjo la eclosión más rápida de los huevos y acortó la duración del período larval, lo cual generó una mayor cantidad de adultos en un período de tiempo más acotado,

aumentando por ende, las poblaciones de anofelinos. Además, al aumentar la temperatura, el ciclo gonotrófico del mosquito hembra se acorta, lo que aumenta la frecuencia de ingestas sanguíneas, es decir la tasa de picaduras (Lindblade et al., 2000; Patz et al., 2000; Sáez-Sáez et al., 2007).

Lindblade et al. (2000), no sólo demostraron que un incremento de la temperatura aumentó el número de adultos de *Anopheles (Cellia) gambiae* que reposaban dentro de las viviendas, sino también que la tasa de picadura fue mayor en aquellas localidades donde la temperatura fue más alta. Por otro lado, diferentes pruebas de laboratorio demostraron la reducción del ciclo gonotrófico de *An. albimanus* cuando estos fueron expuestos a temperaturas entre 24 ° C a 30 ° C (Rúa et al., 2005).

En el trabajo de Afrane et al. (2006), los autores reportaron una reducción del ciclo gonotrófico en *An. gambiae* de 0,9 a 1,7 días en localidades de Iguhu (Uganda) donde la temperatura fue más alta. Por otra parte, el período de incubación extrínseco del parásito guarda una relación directa con la temperatura, ya que al aumentar la misma, el tiempo de incubación del parásito *Plasmodium* es menor (Patz et al., 2000; López Vélez & Molina Moreno, 2005; Afrane et al., 2006; Sáez-Sáez et al., 2007; Ahmadian Marj et al., 2008) lo cual incrementa el tiempo de vida infectiva del vector. Así, por ejemplo, el período extrínseco de *Plasmodium falciparum* en *An. gambiae* se redujo 17,3 días (de 55,5 a 38,2 días) cuando la temperatura aumentó de 18 ° C a 18,9 ° C (Lindblade et al., 2000). En líneas generales, en el mosquito, el ciclo gonotrófico dura 2-3 días coincidiendo con las picaduras de las hembras en busca de sangre (López Vélez & Molina Moreno, 2005).

Esta relación entre la aparición de los casos de Malaria y la temperatura fue reportada para el país anteriormente por Dantur Juri et al. (2009), quienes mostraron que los casos de Malaria en las localidades de El Oculito y Aguas Blancas (departamento de Orán, provincia de Salta) se encontraban asociados a la temperatura media y máxima media, entre otras variables. En El Oculito, un aumento de la temperatura máxima media provocó un aumento del riesgo de aparición de casos de Malaria. Para Aguas Blancas un aumento de la temperatura media mensual y la humedad relativa produjo un aumento en el riesgo de aparición de casos de Malaria.

Por último, Sáez-Sáez et al. (2007) analizaron la relación entre la precipitación y la temperatura sobre la incidencia de la enfermedad en el estado de Sucre (Venezuela). En dicho trabajo, los casos de Malaria y las variables climáticas mostraron una correlación positiva, resultando la precipitación y la temperatura del aire, las variables que mejor explicaron la aparición de los casos de Malaria

En este trabajo, en el modelo A, los casos de Malaria también estuvieron influenciados por una disminución del NDVI medio, y en el modelo B los casos de Malaria se vieron también afectados por una disminución del NDWI medio. Esto podría ser debido a que ambos índices se encuentran relacionados, el NDVI mide el estado de la vegetación, su vigor y cuan verde se encuentra en relación al proceso de fotosíntesis. Esto, a su vez, se encuentra relacionado positivamente a condiciones ambientales como ser la precipitación, la humedad y la temperatura. Mientras tanto, el NDWI es un índice que mide el contenido de agua en la vegetación y por lo tanto es un indicador indirecto de las condiciones de humedad del suelo y del ambiente. En definitiva, un aumento de las precipitaciones produciría un aumento en el NDWI y en el NDVI. Es sabido que las precipitaciones generan las condiciones favorables para la creación de nuevos hábitats larvales, pero si estas son muy abundantes, se producirían inundaciones que eliminarían por arrastre los criaderos de los anofelinos (Dantur Juri et al., 2009).

Si bien existen investigaciones que difieren con los resultados obtenidos en el presente trabajo y que muestran como el NDVI se encuentra relacionado con un incremento de casos Malaria, en un trabajo llevado a cabo en Bangladesh, Haque et al. (2010) analizaron los casos de Malaria en relación a variables meteorológicas y ambientales como ser la precipitación, la temperatura, la humedad y el NDVI. Los autores reportaron que un aumento del 0,1 en el NDVI mensual estaba asociado a una disminución del 30,4 % de los casos de Malaria.

Para finalizar, es importante tener en cuenta que la dinámica de la Malaria es muy compleja y que no sólo intervienen factores ambientales, sino también sociales, económicos, políticos, etc. La calidad de las viviendas (que se encuentra relacionada a su vez a las condiciones económicas de la población), las condiciones de higiene, las acciones llevadas a cabo por los organismos de salud pública, el desplazamiento y la



migración de las personas entre zonas de transmisión endémica, entre otros, son factores que afectan directa e indirectamente a la dinámica de la enfermedad (Keating et al., 2003; Vargas Herrera 2003; Pattanayak et al., 2006; Rodríguez et al., 2008).

## 6.2 CONCLUSIONES

---

- Para San Ramón de la Nueva Orán se observó, durante el periodo de estudio, una fluctuación estacional de los casos de Malaria, con una mayor cantidad de enfermos reportada para los meses de verano. Además, la aparición de los casos de Malaria estaría relacionada con la actividad agrícola llevada a cabo por adultos jóvenes (de 15 a 45 años) pertenecientes al sexo masculino.
- Se generó una importante serie temporal de imágenes Landsat 5 TM y 7 TM del departamento de Orán y San Martín (provincia de Salta) que se encuentra disponible para su libre utilización. La misma cuenta con las imágenes satelitales sin procesar, con el índice normalizado de vegetación (NDVI), el índice normalizado de agua (NDWI) y la temperatura de superficie (LST) para cada una de las imágenes que componen la serie.
- Se generó un modelo ARIMA multivariado que demostró ser útil para la predicción de casos de Malaria en San Ramón de la Nueva Orán. Las variables ambientales relacionadas a la aparición de casos según el modelo propuesto fueron el NDVI máximo y el NDWI medio con un retraso de 5 meses para este último.
- La relación entre los factores climáticos/ambientales y los casos de Malaria fue cuantificada mediante modelos de regresión multinivel de Poisson, calculándose para tal fin la Razón de la Tasa de Incidencia (*IRR*). Este análisis mostró que los casos de Malaria estuvieron asociados a un aumento en la temperatura media como así también a una disminución del NDVI.

## REFERENCIAS BIBLIOGRÁFICAS

---

- Adimi, F.; Soebiyanto, R.P; Safi, N. & Kiang, R. 2010. Towards malaria risk prediction in Afghanistan using remote sensing. *Malaria Journal* 9 (125).
- Afrane, Y.A.; Zhou, G.; Lawson, B.W.; Githeko, A.K. & Yan, G. 2006. Effects of microclimatic changes caused by deforestation on the survivorship and reproductive fitness of *Anopheles gambiae* in western kenya highlands. *American Journal of Tropical Medicine and Hygiene* 74: 772-778.
- Ahmadian Marj, A.; Mobasheri, M.R.; Valadanzouje, M.J.; Rezaei, Y. & Abaei, M.R. 2008. Using Satellite Images in Determination of Malaria Outbreaks Potential Region. *Nature Precedings*: 1-28.
- Allard, R. 1998. Use of time-series analysis in infectious disease surveillance. *Bulletin of the World Health Organization* 76 (4): 327-333.
- Arroyo, A.R. 2004. Diagnostico productivo del departamento de Orán. Estación Experimental de Cultivos Tropicales Yuto. INTA Orán, Salta.
- Augier, L. 2005. Estudios biosistemáticos de mosquitos anofelinos, familia Culicidae. Tesis Doctoral. Universidad Nacional de Tucumán, Argentina.
- Bejarano, J. F. R. 1956. Distribución en altura del género *Anopheles* y del paludismo en la República Argentina. *Revista de la Sanidad Militar* 55: 7-24.
- Bouma, M.J.; Dye, C. & Van Der Kaay, H.J. 1996. *Falciparum* malaria and climate change in the northwest frontier province of Pakistan. *The American Society of Tropical Medicine and Hygiene*. 131-137.
- Bronner, U.; Divis, P.C.; Färnert, A.; & Singh, B. 2009. Swedish traveller with *Plasmodium knowlesi* malaria after visiting Malaysian Borneo. *Malaria Journal* 8(15).
- Brown, A.; Martinez Ortiz, U.; Acerbi, M. & Corcuera, J. 2006. La Situación Ambiental Argentina 2005. Fundación Vida Silvestre. Buenos Aires, Argentina.
- Brown, A.D.; Blendinger, P.G.; Lomáscolo, T. & Bes, P.G. 2009. Selva pedemontana de las Yungas. Historia natural, ecología y manejo de un ecosistema en peligro.

- Fundación Proyungas. Ediciones del Subtrópico. Yerba Buena, Tucumán, Argentina.
- 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* 113: 893–903.
- Ceccato, P.; Connor, S.J.; Jeanne, I. & Thomson, M.C. 2005. Application of Geographical Information Systems and Remote Sensing technologies for assessing and monitoring malaria risk. *Parassitologia* 47: 81-96.
- Curto, S.I., Carbajo A.E. & Boffi, R. 2003. Aplicación de Sistemas de Información Geográfica. Epidemiología. Caso de estudio: Malaria en la Argentina (1902-2000). *Contribuciones Científicas*: 239-248. GAEA Sociedad Argentina de Estudios Geográficos. Buenos Aires.
- Dambach, P.; Machault, V.; Lacaux, J. P.; Vignolles, C.; Sié, A. & Sauerborn, R. 2012. Utilization of combined remote sensing techniques to detect environmental variables influencing malaria vector densities in rural West Africa. *International Journal of Health Geographics* 11( 8).
- Dantur Juri, M.J.; Zaidenberg, M. & Almirón, W. 2003. Fluctuación estacional de *Anopheles (Anopheles) pseudopunctipennis* (Diptera: culicidae) en un área palúdica de Salta, Argentina. *Entomología y Vectores*. 10: 457-468.
- Dantur Juri, M.J.; Zaidenberg, M. & Almiron, W.R. 2005. Distribución espacial de *Anopheles (Anopheles) pseudopunctipennis* (Diptera: Culicidae) en un área palúdica de las Yungas de Salta, Argentina. *Revista de Saúde Pública*. 39: 565-570.
- Dantur Juri, M.J. 2009. Estudios bioecológicos de *Anopheles* (Diptera: Culicidae) en las Yungas argentinas. Tesis Doctoral. Universidad Nacional de Tucumán, Argentina.
- Dantur Juri, M.J.; Zaidenberg, M.; Claps, G.L.; Santana, M. & Almirón, W. 2009. Malaria transmission in two localities in north-western Argentina. *Malaria Journal* 8 (18).

- Dantur Juri, M.J.; Claps, G.L; Santana, M.; Zaidenberg, M. & Almirón, W.R. 2010.a. Abundance patterns of *Anopheles pseudopunctipennis* and *Anopheles argyritarsis* in northwestern Argentina. *Acta Tropica* 115: 234-241.
- Dantur Juri, M.J.; Almirón, W.R. & Claps, G.L. 2010 b. Population fluctuation of *Anopheles* (Diptera: Culicidae) in forest and forest edge habitats in Tucumán province, Argentina. *Journal of Vector Ecology* 35: 28-34.
- Estallo, E.L.; Lamfri, M.; Scavuzzo, C.M.; Ludueña Almeida, F.; Intrioni, M.V.; Zaidenberg, M. & Almirón, W.R. 2008. Models for predicting *Aedes aegypti* larval indices based on satellite images and climatic variables. *Journal of the American Mosquito Control Association* 24: 368–376.
- Estallo, E. L.; Ludueña-Almeida, F. F.; Visintin, A. M.; Scavuzzo, C. M.; Lamfri, M. A.; Introini, M. V.; Zaidenberg, M. & Almirón, W. R. 2012. Effectiveness of normalized difference water index in modelling *Aedes aegypti* house index. *International Journal of Remote Sensing* 33(13): 4254-4265.
- Ferral, A. 2012. Análisis espacio-temporal del efecto del sistema de aireación artificial en el embalse San Roque. Integración de datos de campo y técnicas geoespaciales. Tesis de maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias (AEARTE). Universidad Nacional de Córdoba y Comisión Nacional de Actividades Espaciales.
- Gao, B. 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment* 58:257-266.
- García Rodríguez, M. 2004. San Ramón de la Nueva Orán. Ciudad encajonada y dispersa. Agencia de extensión rural Orán, INTA.
- Gaudart, J.; Touré, O.; Dessay, N.; Dicko, A.L.; Ranque, S.; Forest, L.; Demongeot, J. & Doumbo, O.K. 2009. Modelling malaria incidence with environmental dependency in a locality of Sudanese savannah area, Mali. *Malaria Journal* 8(61).
- Githeko, A.K; Lindsay, S.W; Confalonieri, U.E & Patz, J.A. 2000. Climate change and vector-borne diseases: a regional analysis. *Bulletin of the World Health Organization* 78(9).

- Gobierno de la provincia de Salta. 2009. Plan de ordenamiento territorial de las áreas boscosas de la provincia de Salta. Documento técnico. Disponible en: <http://www.prograno.org/docs/OT%20Areas%20Boscosas%20Salta%20%2830Jun09%29%20.pdf>
- Haque, U.; Hashizume, M.; Glass, G.E.; Dewan, A.M., Overgaard, H.J. & Yamamoto, T. 2010. The Role of Climate Variability in the Spread of Malaria in Bangladeshi Highlands. *PLoS ONE* 5(12): e14341. doi:10.1371/journal.pone.0014341
- Hay, S.I., Snow, R.W. and Rogers, D.J. 1998. Prediction of malaria seasons in Kenya using multi-temporal meteorological satellite sensor data. *Transactions of the Royal Society of Tropical Medicine and Hygiene* 92: 12– 20.
- Helfenstein, U. 1991. The use of transfer function models, intervention analysis and related time series methods in epidemiology. *International Journal of Epidemiology* 20(3): 808-815.
- INDEC. 2010. Instituto Nacional de Estadística y Censos. Censo Nacional de Población, Hogares y Viviendas 2010.
- Kalluri, S.; Gilruth, P.; Rogers, D. & M., Szczur. 2007. Review Surveillance of Arthropod Vector-Borne Infectious Diseases Using Remote Sensing Techniques: A Review. *PLoS Pathogens* 3(10).
- Kiszewski, A.; Mellinger, M.; Spielman, A.; Malaney, P.; Ehrlich, S. & Sachs, J. 2004. A global index representing the stability of malaria transmission. *American Journal of Tropical Medicine and Hygiene* 70: 486–498.
- Lindblade, K.A.; Walker, E.D.; Onapa, A.W.; Katungu, J. & Wilson, M.L. 2000. Land use change alters malaria transmission parameters by modifying temperature in a highland area of Uganda. *Tropical Medicine and International Health* 5: 263–274.
- Lindsay, S.W. & W.J.M. Martens. 1998. Malaria in the African highlands: past, present and future. *Bulletin of the World Health Organization* 76 (1): 33-45.
- Loha, E. & Lindtjørn B. 2010. Model variations in predicting incidence of Plasmodium falciparum malaria using 1998-2007 morbidity and meteorological data from south Ethiopia. *Malaria Journal* 9:166.

- López Vélez, R. & Molina Moreno, R. 2005. Cambio Climático en España y Riesgo de Enfermedades Infecciosas y Parasitarias transmitidas por Artrópodos y Roedores. *Revista Española de Salud Pública* 79: 177-190.
- Luz, P. M.; Mendes, B. V.; Codeço, C. T.; Struchiner, C. J. & Galvani, A. P. 2008. Time series analysis of dengue incidence in Rio de Janeiro, Brazil. *The American Journal of Tropical Medicine and Hygiene* 79(6): 933-939.
- Machault, V.; Vignolles, C.; Borch, F.; Vounatsou, P.; Briolant, S., Lacaux, J. P. & Rogier, C. 2011. The use of remotely sensed environmental data in the study of malaria. *Geospatial Health* 5 (2): 151-168.
- Malaria Atlas Project, map: URL: <http://www.map.ox.ac.uk/>
- Martens, W.J.; Niessen, L.N.; Rotmans, J.; Jetten, T.H & McMichael, A.J. 1995. Potential Impact of Global Climate Change on Malaria Risk. *Environmental Health Perspectives* 103 (5): 459-464.
- McFeeters, S.K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing* 17(7): 1425-1432.
- Midekisa, A.; Senay, G.; Henebry, G. M.; Semuniguse, P. & Wimberly, M. C. 2012. Remote sensing-based time series models for malaria early warning in the highlands of Ethiopia. *Malaria Journal* 11(1): 165.
- Mühlens, P, Dios, R. L., Petrocchi, J. & Zuccarini, J. A. 1925. Paludismo en el Norte Argentino. *Revista del Instituto Bacteriológico del Departamento Nacional de Higiene*. 4: 207-289.
- Najera, J.A.; Koumetsov, R.L. & Delacollette, C. 1998. Malaria epidemics detection and control forecasting and prevention. World Health Organization.
- Organización Panamericana de Salud. 2011. Informe de la situación de paludismo en las Américas.
- Patz, J.A.; Graczyk, T.K.; Gellera, N. & Vittor, A.Y. 2000. Effects of environmental change on emerging parasitic diseases. *International Journal for Parasitology* 30: 1395-1405.
- Patz, J.A.; Daszak, P.; Tabor, M.B.; Alonso Aguirre, A.; Pearl, M.; Epstein, J.; Wolfe, N.D.; Marm Kilpatrick, M; Fofopoulos, J.; Molyneux, D; Bradley, D.J. and Members of

- the Working Group on Land Use Change and Disease Emergence. 2004. Meeting Report: Unhealthy Landscapes: Policy Recommendations on Land Use Change and Infectious Disease Emergence. *Environmental Health Perspectives* 112(10): 1092-1098
- Poderti, A. 1995. San Ramón de la Nueva Orán: una ciudad, muchas historias. Salta: Fundación Banco del Noroeste. Disponible en: <http://www.aliciapoderti.com.ar/sanramon.doc>
- Ramírez, A. P.; Buitrago, J. I.; González, J. P. P.; Carrasquilla, G. & Morales, A. H. 2014. Frequency and tendency of malaria in Colombia, 1990 to 2012: a descriptive study. *Malaria Journal* 13(1): 202.
- Rodríguez, M.H.; Ulloa García, A. & Ramsey Willoquet, J.M. 2008. Manual para la vigilancia y el control del paludismo en Mesoamérica. Instituto Nacional de Salud Pública. Cuernavaca, Morelos, México.
- Rodríguez Morales, A.J., 2005. Ecoepidemiología y Epidemiología Satelital: nuevas herramientas en el manejo de problemas en Salud Pública. *Rev Peru Med Exp Salud Publica* 22: 54-63.
- Roll Back Malaria. 2001. Malaria Early Warning Systems -A Framework for Field Research in Africa. Concepts, indicators and partners.
- Roll Back Malaria. 2008. The Global Malaria Action Plan: for a malaria free-world.
- Rosa, R.; Marini, G.; Bolzoni, L.; Neteler, M.; Metz, M.; Delucchi, L. & Rizzoli, A. 2014. Early warning of West Nile virus mosquito vector: climate and land use models successfully explain phenology and abundance of *Culex pipiens* mosquitoes in north-western Italy. *Parasites & vectors* 7(1): 269.
- Rotela, C.; Fouque, F.; Lamfri, M.; Sabatier, P.; Introini, V.; Zaidenberg, M. & Scavuzzo, C. 2007. Space-time analysis of the dengue spreading dynamics in the 2004 Tartagal outbreak, Northern Argentina. *Acta Tropica* 103: 1-13.
- Rotela, C. 2013. Desarrollo de Modelos e Indicadores Remotos de Riesgo Epidemiológico de Dengue en Argentina. Tesis Doctoral. Universidad Nacional de Córdoba, Argentina.
- Rúa, G.; Quiñónez, M.; Vélez, D.; Zuluaga, J.; Rojas, W.; Poveda, G. & Ruiz, D. 2005. Laboratory estimation of the effects of increasing temperatures on the duration

- of gonotrophic cycle of *Anopheles albimanus* (Diptera: Culicidae). *Memorias Instituto Oswaldo Cruz*. 100: 515-520.
- Rúa-Urbe, G. L.; Suárez-Acosta, C.; Chauca, J.; Ventosilla, P. & Almanza, R. 2013. Modelado del efecto de la variabilidad climática local sobre la transmisión de dengue en Medellín (Colombia) mediante análisis de series temporales. *Biomédica* 33: 142-52.
- Rubio-Palis, Y. & Zimmerman, R.H. 1997. Regional classification of malaria vectors in the Neotropics. *Journal of Medical Entomology* 34: 499-510.
- Sáez Sáez, V.; Martínez, J.; Rubio Palis, Y. & Delgado, L. 2007. Evaluación semanal de la relación malaria, precipitación y temperatura del aire en la Península de Paria, estado Sucre, Venezuela. *Boletín De Malariología y Salud Ambiental* 47: 177-189.
- Sanabria, H.; Hernández, A.V.; Villafuerte, A. & P. Erazo. 2004. Percepción y condiciones de trabajo de personas que tuvieron malaria. *Revista Peruana de Medicina Experimental y Salud Pública* 21(4).
- Scavuzzo, C.M.; Lamfri, M.A.; Rotela, C.; Porcasi, X. & E. Estallo. 2006. Satellite Image Applied to Epidemiology, Experience of the Gulich Institute in Argentina. *Space Technology as a Tool for Delivery e-Health*. United Nations.
- Scavuzzo & FEA. 2005. Workshop on the use of space technology for human health for the benefit of the countries in Latin American and Caribbean. *Revista SELPER. Edición especial*
- United States Geological Survey (USGS). Sitio de internet. <http://www.usgs.gov/>
- Vargas Herrera, J. 2003. Prevención y control de la Malaria y otras enfermedades transmitidas por vectores en el Perú. *Revista Peruana de Epidemiología* 11: 1-18.
- Wangdi, K.; Singhasivanon, P.; Silawan, T.; Lawpoolsri, S.; White, N. J. & Kaewkungwal, J. 2010. Development of temporal modelling for forecasting and prediction of malaria infections using time-series and ARIMAX analyses: a case study in endemic districts of Bhutan. *Malaria Journal* 9: 251.
- World Health Organization & UNICEF. 2005. World Malaria Report. Geneva.
- World Health Organization. 1993. A global strategy for malaria control. WHO Library
- World Health Organization. 2008. World Malaria Report 2008. WHO Library.



- World Health Organization. 2010. World Malaria Report 2010. WHO Library.
- World Health Organization. 2011. World Malaria Report 2011. WHO Library.
- World Health Organization. 2012. World Malaria Report 2012. WHO Library.
- World Health Organization, 2013. World Malaria Report 2013. WHO Library.
- Xu, H. 2006. Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing* 27(14): 3025–3033.
- Wu, P. C.; Guo, H. R.; Lung, S. C.; Lin, C. Y. & Su, H. J. 2007. Weather as an effective predictor for occurrence of dengue fever in Taiwan. *Acta tropica* 103 (1): 50-57.
- Zhang, Z.; Ward, M.; Gao, J.; Wang, Z.; Yao, B.; Zhang, T. & Jiang, Q. 2013. Remote sensing and diseases control in China: past, present and future. *Parasites & Vectors* 6: 11.

## ANEXOS

---

**Anexo A.** Tabla de las imágenes que componen la serie temporal Landsat utilizada.

<b>Fecha de adquisición</b>	<b>Satélite y sensor</b>	<b>Path/row</b>	<b>Origen</b>
14/01/1986	Landsat 5 TM	231/76	USGS
11/06/1987	Landsat 4 TM	230/76	USGS
20/04/1986	Landsat 5 TM	231/76	USGS
25/07/1986	Landsat 5 TM	231/76	USGS
03/08/1986	Landsat 5 TM	230/76	USGS
10/08/1986	Landsat 5 TM	231/76	USGS
20/09/1986	Landsat 5 TM	230/76	USGS
22/10/1986	Landsat 5 TM	230/76	USGS
09/12/1986	Landsat 5 TM	230/76	USGS
22/08/1987	Landsat 5 TM	230/76	USGS
23/09/1987	Landsat 5 TM	230/76	USGS
01/11/1987	Landsat 5 TM	231/76	USGS
04/01/1988	Landsat 5 TM	231/76	USGS
29/01/1988	Landsat 5 TM	230/76	USGS
02/04/1988	Landsat 5 TM	230/76	USGS
07/07/1988	Landsat 5 TM	230/76	USGS
08/08/1988	Landsat 5 TM	230/76	USGS
31/08/1988	Landsat 5 TM	231/76	USGS
02/10/1988	Landsat 5 TM	231/76	USGS
27/10/1988	Landsat 5 TM	230/76	USGS
12/11/1988	Landsat 5 TM	230/76	USGS
06/01/1989	Landsat 5 TM	231/76	USGS
15/01/1989	Landsat 5 TM	230/76	USGS
04/03/1989	Landsat 5 TM	230/76	USGS
20/03/1989	Landsat 5 TM	230/76	USGS
23/05/1989	Landsat 5 TM	230/76	USGS
17/07/1989	Landsat 5 TM	231/76	USGS
11/08/1989	Landsat 5 TM	230/76	USGS
03/09/1989	Landsat 5 TM	231/76	USGS
19/09/1989	Landsat 5 TM	231/76	USGS
21/10/1989	Landsat 5 TM	231/76	USGS
21/10/1989	Landsat 5 TM	231/76	USGS
15/11/1989	Landsat 5 TM	230/76	USGS
08/12/1989	Landsat 5 TM	231/76	USGS

<b>25/01/1990</b>	Landsat 5 TM	231/76	USGS
<b>14/03/1990</b>	Landsat 5 TM	231/76	USGS
<b>10/05/1990</b>	Landsat 5 TM	230/76	USGS
<b>26/05/1990</b>	Landsat 5 TM	230/76	USGS
<b>30/08/1990</b>	Landsat 5 TM	230/76	USGS
<b>15/09/1990</b>	Landsat 5 TM	230/76	USGS
<b>01/10/1990</b>	Landsat 5 TM	230/76	USGS
<b>05/01/1991</b>	Landsat 5 TM	230/76	USGS
<b>17/03/1991</b>	Landsat 5 TM	231/76	USGS
<b>29/05/1991</b>	Landsat 5 TM	230/76	USGS
<b>17/08/1991</b>	Landsat 5 TM	230/76	USGS
<b>11/10/1991</b>	Landsat 5 TM	231/76	USGS
<b>30/12/1991</b>	Landsat 5 TM	231/76	USGS
<b>19/03/1992</b>	Landsat 5 TM	231/76	USGS
<b>13/04/1992</b>	Landsat 5 TM	230/76	USGS
<b>09/07/1992</b>	Landsat 5 TM	231/76	USGS
<b>25/07/1992</b>	Landsat 5 TM	231/76	USGS
<b>20/09/1992</b>	Landsat 5 TM	230/76	USGS
<b>22/10/1992</b>	Landsat 5 TM	230/76	USGS
<b>07/11/1992</b>	Landsat 5 TM	230/76	USGS
<b>14/11/1992</b>	Landsat 5 TM	231/76	USGS
<b>30/11/1992</b>	Landsat 5 TM	231/76	USGS
<b>10/01/1993</b>	Landsat 5 TM	230/76	USGS
<b>18/02/1993</b>	Landsat 5 TM	231/76	USGS
<b>27/02/1993</b>	Landsat 5 TM	230/76	USGS
<b>03/06/1993</b>	Landsat 5 TM	230/76	USGS
<b>19/06/1993</b>	Landsat 5 TM	230/76	USGS
<b>22/08/1993</b>	Landsat 5 TM	231/76	USGS
<b>29/08/1993</b>	Landsat 5 TM	231/76	USGS
<b>14/09/1993</b>	Landsat 5 TM	231/76	USGS
<b>16/10/1993</b>	Landsat 5 TM	231/76	USGS
<b>15/07/1994</b>	Landsat 5 TM	231/76	USGS
<b>19/10/1994</b>	Landsat 5 TM	231/76	USGS
<b>04/11/1994</b>	Landsat 5 TM	231/76	USGS
<b>22/12/1994</b>	Landsat 5 TM	231/76	USGS
<b>04/09/1995</b>	Landsat 5 TM	231/76	USGS
<b>20/09/1995</b>	Landsat 5 TM	231/76	USGS
<b>22/10/1995</b>	Landsat 5 TM	231/76	USGS
<b>03/01/1996</b>	Landsat 5 TM	230/76	USGS
<b>30/02/1996</b>	Landsat 5 TM	230/76	USGS
<b>24/04/1996</b>	Landsat 5 TM	230/76	USGS
<b>26/05/1996</b>	Landsat 5 TM	230/76	USGS
<b>29/07/1996</b>	Landsat 5 TM	230/76	USGS

<b>14/08/1996</b>	Landsat 5 TM	230/76	USGS
<b>06/09/1996</b>	Landsat 5 TM	231/76	USGS
<b>17/10/1996</b>	Landsat 5 TM	230/76	USGS
<b>25/11/1996</b>	Landsat 5 TM	231/76	USGS
<b>30/06/1997</b>	Landsat 5 TM	230/76	USGS
<b>24/08/1997</b>	Landsat 5 TM	231/76	USGS
<b>11/10/1997</b>	Landsat 5 TM	231/76	USGS
<b>20/10/1997</b>	Landsat 5 TM	230/76	USGS
<b>23/05/1998</b>	Landsat 5 TM	231/76	USGS
<b>01/06/1998</b>	Landsat 5 TM	230/76	USGS
<b>12/09/1998</b>	Landsat 5 TM	231/76	USGS
<b>07/10/1998</b>	Landsat 5 TM	230/76	USGS
<b>02/01/1999</b>	Landsat 5 TM	231/76	USGS
<b>19/02/1999</b>	Landsat 5 TM	231/76	USGS
<b>17/04/1999</b>	Landsat 5 TM	230/76	USGS
<b>26/05/1999</b>	Landsat 5 TM	231/76	USGS
<b>06/07/1999</b>	Landsat 5 TM	230/76	USGS
<b>30/08/1999</b>	Landsat 5 TM	231/76	USGS
<b>24/09/1999</b>	Landsat 5 TM	230/76	USGS
<b>10/10/1999</b>	Landsat 5 TM	230/76	USGS
<b>13/12/1999</b>	Landsat 5 TM	230/76	USGS
<b>06/02/2000</b>	Landsat 5 TM	231/76	USGS
<b>10/04/2000</b>	Landsat 5 TM	231/76	USGS
<b>24/07/2000</b>	Landsat 5 TM	230/76	USGS
<b>16/08/2000</b>	Landsat 5 TM	231/76	USGS
<b>26/09/2000</b>	Landsat 5 TM	230/76	USGS
<b>03/10/2000</b>	Landsat 5 TM	231/76	USGS
<b>07/01/2001</b>	Landsat 5 TM	231/76	USGS
<b>24/02/2001</b>	Landsat 5 TM	231/76	USGS
<b>03/08/2001</b>	Landsat 5 TM	231/76	USGS
<b>28/08/2001</b>	Landsat 5 TM	230/76	USGS
<b>23/11/2001</b>	Landsat 5 TM	231/76	USGS
<b>18/12/2001</b>	Landsat 5 TM	230/76	USGS
<b>03/01/2002</b>	Landsat 5 TM	230/76	USGS
<b>11/02/2002</b>	Landsat 5 TM	231/76	USGS
<b>08/03/2002</b>	Landsat 5 TM	230/76	USGS
<b>10/09/2003</b>	Landsat 5 TM	231/76	USGS
<b>21/10/2003</b>	Landsat 5 TM	230/76	USGS
<b>06/11/2003</b>	Landsat 5 TM	230/76	USGS
<b>16/01/2004</b>	Landsat 5 TM	231/76	USGS
<b>26/02/2004</b>	Landsat 5 TM	230/76	USGS
<b>14/04/2004</b>	Landsat 5 TM	230/76	USGS
<b>19/07/2004</b>	Landsat 5 TM	230/76	USGS

<b>05/09/2004</b>	Landsat 5 TM	230/76	USGS
<b>23/10/2004</b>	Landsat 5 TM	230/76	USGS
<b>11/01/2005</b>	Landsat 5 TM	230/76	USGS
<b>16/03/2005</b>	Landsat 5 TM	230/76	USGS
<b>03/05/2005</b>	Landsat 5 TM	230/76	USGS
<b>13/07/2005</b>	Landsat 5 TM	231/76	USGS
<b>14/08/2005</b>	Landsat 5 TM	231/76	USGS
<b>17/10/2005</b>	Landsat 5 TM	231/76	USGS
<b>25/10/1999</b>	Landsat 7 ETM+	231/76	USGS
<b>26/11/1999</b>	Landsat 7 ETM+	231/76	USGS
<b>18/09/2000</b>	Landsat 7 ETM+	230/76	USGS
<b>07/12/2000</b>	Landsat 7 ETM+	230/76	USGS
<b>24/01/2001</b>	Landsat 7 ETM+	230/76	USGS
<b>09/02/2001</b>	Landsat 7 ETM+	230/76	USGS
<b>13/03/2001</b>	Landsat 7 ETM+	230/76	USGS
<b>29/03/2001</b>	Landsat 7 ETM+	230/76	USGS
<b>14/04/2001</b>	Landsat 7 ETM+	230/76	USGS
<b>24/06/2001</b>	Landsat 7 ETM+	231/76	USGS
<b>04/08/2001</b>	Landsat 7 ETM+	230/76	USGS
<b>11/01/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>16/03/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>20/06/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>06/07/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>13/07/2002</b>	Landsat 7 ETM+	231/76	USGS
<b>23/08/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>24/09/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>26/10/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>11/11/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>29/12/2002</b>	Landsat 7 ETM+	230/76	USGS
<b>30/01/2003</b>	Landsat 7 ETM+	230/76	USGS
<b>06/02/2003</b>	Landsat 7 ETM+	231/76	USGS
<b>20/04/2003</b>	Landsat 7 ETM+	230/76	USGS
<b>06/05/2003</b>	Landsat 7 ETM+	230/76	USGS



15		.5949889	.0374858	.5211425	.6688353
16		.6624579	.0365591	.5904371	.7344787
17		.653328	.032267	.5897626	.7168934
18		.6232898	.03713	.5501444	.6964353
19		.5636351	.038215	.4883522	.6389179
20		.5479179	.062097	.4255879	.6702479
-----					
NDWI_med1					
1		.2670695	.0404141	.1874545	.3466846
2		.2445623	.0396029	.1665454	.3225792
3		.2675943	.0330752	.2024368	.3327519
4		.2482613	.037869	.17366	.3228625
5		.2890217	.062852	.1652045	.4128389
6		.3010042	.0278309	.2461779	.3558306
7		.3207981	.035535	.2507948	.3908014
8		.2719946	.044174	.1849726	.3590165
9		.3033212	.0246804	.2547012	.3519412
10		.1362288	.0463404	.0449391	.2275185
11		.2049163	.0406153	.124905	.2849277
12		.2123833	.0257929	.1615719	.2631948
13		.1696124	.0408608	.0891175	.2501073
14		.2815277	.0323314	.2178354	.3452201
15		.2706982	.0323718	.2069263	.33447
16		.2971441	.0362599	.2257128	.3685754
17		.283723	.0342271	.2162963	.3511497
18		.2869659	.0305182	.2268455	.3470862
19		.2922581	.029673	.2338028	.3507134
20		.2331393	.0541833	.1263992	.3398794
-----					
LST_med1					
1		20.1291	.6994535	18.75119	21.50701
2		19.7389	1.101831	17.56831	21.90949
3		18.04877	1.080169	15.92085	20.17668
4		20.3389	1.203939	17.96716	22.71064
5		19.16917	1.227549	16.75092	21.58741
6		19.91842	1.040843	17.86798	21.96887
7		18.41235	1.068043	16.30833	20.51637
8		19.60758	1.580615	16.4938	22.72137
9		22.42694	.4925559	21.45662	23.39727
10		20.89447	1.20159	18.52736	23.26158
11		21.18058	1.769797	17.69412	24.66705
12		15.66812	1.170096	13.36305	17.97318
13		20.87968	.8451062	19.21484	22.54453
14		18.44197	1.39327	15.69725	21.18668
15		19.62602	1.400292	16.86747	22.38457
16		20.27619	1.183173	17.94536	22.60702
17		21.42352	1.282387	18.89725	23.9498
18		20.58042	1.257343	18.10348	23.05737
19		20.63052	1.612716	17.4535	23.80755
20		20.80548	.7399701	19.34776	22.26321
-----					