
Usos de herramientas geoespaciales en la detección de áreas con riesgo epidemiológico a partir de variables biofísicas y casos de dengue en Jujuy - Argentina

Por:

Lic. María Nazarena Ramona ROJAS

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 CÓRDOBA

Junio, 2016

©IG-CONAE/UNC 2016

©FAMAF-UNC 2016

Director:

Dr. Carlos RIPOLL

Co-Director:

Dr. Camilo ROTELA



Este trabajo se distribuye bajo licencia Creative Commons
<https://creativecommons.org/licenses/by-nc-nd/2.5/ar/>

UNIVERSIDAD NACIONAL DE CÓRDOBA

Resumen

Facultad de Matemática, Astronomía y Física - FaMAF

MAESTRIA EN APLICACIONES ESPACIALES DE ALERTA Y RESPUESTA
TEMPRANA A EMERGENCIAS

**Usos de herramientas geospaciales en la detección de áreas con riesgo
epidemiológico a partir de variables biofísicas y casos de dengue en Jujuy -
Argentina**

por Lic. María Nazarena Ramona ROJAS

El Dengue es en la actualidad una de las enfermedades transmitidas por vectores de mayor prevalencia en el continente Sudamericano. En Argentina, se presenta en forma de brotes esporádicos desde 1998, con casos autóctonos en diversas provincias entre ellas, Jujuy. Es un arbovirus de la familia de los *Flaviviridae* el agente causal de la enfermedad. Este se transmite al hombre (agente susceptible), a través del mosquito *Ae. aegypti*, uno de los principales vectores en el continente sudamericano. El mosquito posee hábitos domésticos. Una de las formas de prevención es a partir de la combinación entre una activa vigilancia epidemiológica y la prevención/control estratégica del vector. En este sentido, esta tesis tiene por objetivo analizar y explicar la variabilidad geográfica de los patrones de distribución de Dengue en la provincia de Jujuy, teniendo presente el brote de 2009. Se realizó un análisis de correlación entre los casos. Con un p-valor de 0.05, el índice de Moran's mostró que los casos responden a patrones de agregación espacial. El test de Knox reveló la existencia de un patrón de distribución de clusters espacio-temporales distintos del azar. Se modeló a nivel provincial, la favorabilidad ambiental para el desarrollo del vector, usando MaxEnt. El modelo con las variables ambientales empleadas tuvo un buen ajuste (AUC = 0.994). Se reveló que la variable "Precipitación acumulada" es una de las que más aporta al modelo. El modelado no jerárquico *Árbol de decisión* arrojó un mapa de riesgo de distribución que se ajusta al modelo real de distribución de los casos humanos del brote.

Se concluye que la utilización de las herramientas geoespaciales empleadas en este trabajo, permitieron hacer un análisis concreto sobre las variables que influyen más en los modelos. Se puede observar perfectamente las áreas de mayor riesgo de transmisión del virus del dengue, tanto a nivel de provincia como de localidad, a fin de priorizar en estos lugares, las estrategias de prevención y control del vector. Los resultados expuestos son de gran importancia para la toma de decisiones en salud pública. Generando el primer antecedente de metodología alternativa para abordar eventos transmitidos por vectores en la provincia de Jujuy.

UNIVERSIDAD NACIONAL DE CÓRDOBA

Resumen

Facultad de Matemática, Astronomía y Física - FaMAF

MAESTRIA EN APLICACIONES ESPACIALES DE ALERTA Y RESPUESTA
TEMPRANA A EMERGENCIAS

**Usos de herramientas geospaciales en la detección de áreas con riesgo
epidemiológico a partir de variables biofísicas y casos de dengue en Jujuy -
Argentina**

por Lic. María Nazarena Ramona ROJAS

Currently Dengue disease is one of the vector-borne diseases transmitted by most prevalent vector in the South American continent. In Argentina, dengue behaves like as sporadic outbreaks since 1998, with native cases in various provinces including Jujuy. Causative agent of the disease, is an arbovirus of the *Flaviviridae* family. This is transmitted to humans (susceptible agent) through the *Ae. aegypti*, one of the main vectors in the South American continent. The mosquito has domestic habits. One form prevention is based on the combination of an active epidemiological surveillance and prevention / strategic vector control. In this sense, the aims of the thesis is to analyze and explain the geographical variability of distribution patterns of Dengue in the province of Jujuy, bearing in mind the outbreak of 2009. A correlation analyze between cases was performed. With a p-value of 0.05, Moran's index showed that cases respond to patterns of spatial aggregation. Knox test showed the existence of a distribution spatio-temporal pattern different to random clusters. It was modeled at provincial level to environmental favorability to vector, using MaxEnt model. The model with environmental variables used showed a good fit (AUC = 0.994). It was showed the variable Çumulative Rainfallis one of the largest provide to the model. The non-hierarchical Decision Tree modeling yielded a *risk map distribution model* wich performance was to similary to true distribution of human cases of the outbreak of 2009. It is concluded that the use of geospatial tools used in this work, allowed to make a concrete analysis of the variables that most influence in the models. It can observe the areas of greatest risk of transmission of dengue virus, at both provincial and locality levels, in order to prioritize on these places, prevention and control of vector strategies. The findings in this work are of great importance for decision-making in public health of province. This is the first antecedent of alternative methodology in order to approach to events transmitted by vectors in the province of Jujuy.

Agradecimientos

Quiero agradecer en primer lugar a las siguientes instituciones: la **Comisión Nacional de Actividades Espaciales (CONAE)** y la **Agencia Espacial Italiana (ASI)** quienes de manera conjunta me brindaron la posibilidad de acceder a la beca de la Maestría en Aplicaciones Espaciales de Alerta y Respuesta Temprana a Emergencias.

A mis Directores de Tesis, **Dr. Carlos Ripoll** y **Dr. Camilo Rotela**, por haberme guiado en el desarrollo de este trabajo y compartido conmigo sus amplios conocimientos y experiencias en el tema.

A **Marcelo Scavuzzo** y a **Mario Lamfri**, por el asesoramiento y colaboración en el desarrollo e interpretación de algunos scripts en IDL.

A **Sofía Lanfri** por la buenísima predisposición y sus valiosos aportes.

A **Sebastián** y **Andres** por la colaboración en el procesamiento de imágenes de Precipitación.

A **Nicolás Mari** y **Patricio Oricchio** del **INTA** por la colaboración en el procesamiento de imágenes MODIS.

A todos los compañeros, docentes de la maestría, a mis amigos. A mis colegas de trabajo del Ministerio de Salud de Jujuy.

A mi familia, a mis padres Irma y Jorge, gracias a los dos por haber depositado en mi el valor de la responsabilidad y el respeto, gracias por haberme apoyado siempre en mis locuras, a mis hermanos y cuñad@s, a mis maravillosos sobrinos, por haberme acompañado siempre, en cada uno de mis propósitos. Y también a Andrés, por sus aportes y por haber compartido conmigo el don maravilloso de la paternidad.

Finalmente quiero agradecer los valiosos aportes del tribunal evaluador al Agrimensor Gabriel Platzeck, a la Dra. Patricia Arena y al Dr. Nicolás Fruto.

Índice general

Resumen	II
Abstract	IV
Agradecimientos	V
Contenidos	VI
Índice de figuras	IX
Lista de Tablas	XII
1. Dengue, Situación actual y herramientas geoespaciales como alternativa de control	1
1.1. Introducción	1
1.1.1. La Enfermedad de Dengue	2
1.1.2. Ecología y ciclo biológico del vector	3
1.1.3. El Huesped	5
1.1.4. El dengue en Argentina	5
1.1.5. Factores ambientales que influyen en el mantenimiento y propagación de dengue y el Sensado Remoto como herramienta en los sistemas de alertas tempranas, para la salud.	6
1.2. Motivación	9
1.3. Objetivo General	9
1.4. Objetivos Específicos	9
2. Jujuy y sus Variables Ambientales	10
2.1. Introducción	10
2.1.1. Lugar de estudio: La provincia de Jujuy	11
2.1.1.1. San Pedro de Jujuy	12
2.1.2. Datos	13
2.1.2.1. Casos Humanos	13
2.1.2.2. Sitios con presencia de <i>Ae. aegypti</i>	13
2.1.2.3. Imágenes Satelitales	14

3. Análisis Espacio-Temporal	19
3.1. Introducción	19
3.1.1. Análisis Espacio-Temporal	19
3.1.1.1. Clusters o Agrupamientos	19
3.1.1.2. Test de Knox	20
3.1.1.3. Desarrollo del método	21
3.1.1.4. Requerimientos para su aplicación	23
3.1.1.5. Las limitaciones del método Knox	23
3.2. Metodología	23
3.2.1. Descripción de los datos	24
3.2.2. Análisis de Clusters Espacio-Temporal	25
3.2.2.1. Aplicación del Test de Knox	25
3.2.2.2. Aplicación de técnicas de Autocorrelación Espacial	27
3.2.2.3. Density Kernel	28
3.3. Discusión	30
3.4. Conclusión	31
4. Modelos predictivos de Dengue (I)	34
4.1. Introducción	34
4.1.1. Modelado para <i>Ae. aegypti</i>	34
4.2. Metodología	36
4.2.1. Favorabilidad Ambiental para <i>Ae. aegypti</i> a nivel provincial, mediante un modelado de Máxima Entropía	36
4.2.2. Modelado Ecológico para <i>Ae. aegypti</i>	41
4.2.2.1. Evaluación de las predicciones	42
4.2.2.2. Preparación de los datos de entrada	42
4.2.2.3. Configuración del programa	43
4.3. Resultados	44
4.3.1. Tasa de Omisión	44
4.3.2. Curva ROC y AUC	44
4.3.3. Curvas de Respuestas	46
4.3.4. Contribución de las variables	48
4.3.5. Test de Jackknife	49
4.3.6. Mapa predictivo	49
4.3.7. Favorabilidad ambiental por localidad	49
4.4. Discusión	51
4.5. Conclusión	56
5. Modelos predictivos de Dengue (II)	58
5.1. Introducción	58
5.2. Metodología	59
5.2.1. Riesgo Urbano	59
5.2.2. Datos	60
5.2.3. Generación de Variables Ambientales	62
5.2.4. Modelo de Regresión Lineal Múltiple	69
5.2.5. Modelo predictivo: Árbol de Decisión	70
5.2.6. Método del Paralelepípedo	72

5.3. Discusión y Conclusión	72
6. Conclusiones generales	77
6.1. Conclusiones	77
6.1.1. Perspectivas a futuro	79
A. DESCARGAR SERIES DE PRODUCTOS MODIS DESDE UN FTP	80
A.1. PARA DESCARGAR UNA SERIE DE PRODUCTOS DE MODIS DES- DE UN FTP	80
A.1.1. DESDE FILEZILA	80
Bibliografía	84

Índice de figuras

1.1.	Huevos de <i>Ae. aegypti</i>	4
1.2.	Pupas y Larvas de <i>Ae. aegypti</i>	4
1.3.	Vista frontal de un Adulto Hembra de <i>Ae. aegypti</i>	5
1.4.	Vista lateral de un Adulto Hembra de <i>Ae. aegypti</i>	5
1.5.	Distribución geográfica de <i>Ae. aegypti</i> (gris claro) y <i>Ae. albopictus</i> (gris oscuro) en las provincias argentinas. Extraído de Vezzani y Carbajo (2008) [1].	6
1.6.	Componente Riesgo Ambiental estimado para el año 2014. Extraído de Plan Nacional de Prevención y Control de Dengue y fiebre Amarilla. Guía de Usuario ERDNU/HAP [2].	8
2.1.	Figura 2.1. Ubicación Geográfica de Jujuy en Argentina.	12
2.2.	Ubicación Geográfica del departamento de San Pedro en Jujuy, con los casos humanos georreferenciados.	13
2.3.	Ubicación Geográfica dentro de la provincia de Jujuy, de las localidades con presencia del vector.	14
2.4.	Mapa mundial de Coberturas de Suelo. Proyecto Globis GlobCover 2009	18
2.5.	Referencias del Mapa de Coberturas de Suelo mundial. Proyecto Globis GlobCover 2009	18
3.1.	a) (izquierda) Distribución espacial de los casos humanos de dengue en 2009, en la localidad de San Pedro. Representación gráfica desde el lenguaje de programación IDL, b) (derecha) Ubicación y distribución espacial de las manzanas de la localidad de San Pedro, en 2009. Imagen desde Google earth.	24
3.2.	Histograma Comparativo de la distribución espacial de los casos reales vs. el azar.	26
3.3.	Superposición de los histogramas de los casos reales y los generados aleatoriamente, distribuidos en el tiempo (a diario).	26
3.4.	Representación gráfica del patrón de distribución en el espacio (en metros) y tiempo (en días), de pares de casos de dengue, formando clusters. Cada píxel representa 50 m de distancia espacial y 1 día, los cortes estan hechos cada 10 píxeles.	27
3.5.	Autocorrelación espacial (Moran's I) de los casos reales. Salida de ArcGis 9.3	28
3.6.	Cociente entre la Distancia media observada y la Distancia media esperada, de los casos reales. Salida de ArcGis 9.3	28
3.7.	(izquierda) Density Kernel. Con un radio de búsqueda de 100 m, la salida del algoritmo muestra la distribución de los clusters dispuestos en la ciudad de San Pedro. (derecha) Superposición de la distribución de los clusters sobre una imagen SPOT de alta resolución espacial.	29
3.8.	Ciudad de San Pedro de Jujuy, con sus calles principales. Imagen obtenida desde Google Earth.	30
3.9.	Secuencia cronológica, por semana (Semana 1 a 6, de izquierda a derecha y de arriba hacia abajo), del brote de dengue en 2009, en la localidad de San Pedro.	32
3.10.	Secuencia cronológica, por semana (Semana 7 a 10, de izquierda a derecha y de arriba hacia abajo), del brote de dengue en 2009, en la localidad de San Pedro.	33

4.1.	a) Mosaico realizado a partir de los tiles del SRTM de 90m (sup. izq.) b) Imágen DEM de la provincia de Jujuy (sup. der.) c) Imagen “slope” para la provincia de Jujuy (inf. izq.) d) Imagen “aspect” para la provincia de Jujuy (inf. der.)	37
4.2.	Ciclo anual de precipitaciones medias mensuales, entre los años 2003 y 2009. Obtenido desde giovanni.gsfc.nasa.gov	38
4.3.	Precipitación acumulada mensual	38
4.4.	Mapa de coberturas de la provincia de Jujuy. Obtenido desde GlobeCover 2009.	39
4.5.	Mapa de Índice de Vegetación Normalizado. Obtenido desde productos MODIS.	40
4.6.	Mapa de Temperatura Superficial de la Tierra, en grados Centígrados. Obtenido desde productos MODIS.	40
4.7.	Gráfico Tasas de omisión	45
4.8.	Gráfico de la Curva ROC (AUC)	45
4.9.	a) (izquierda) Curva de respuesta de la variable <i>Precipitación Acumulada</i> , b) (derecha) Curva de respuesta de la variable <i>DEM</i>	46
4.10.	a) (izquierda) Curva de respuesta de la variable <i>NDVI</i> , b) (derecha) Curva de respuesta de la variable <i>Coberturas</i>	46
4.11.	a) (izquierda) Curva de respuesta de la variable <i>LST</i> , b) (derecha) Curva de respuesta de la variable <i>DEM.Slope</i>	47
4.12.	a) (izquierda) Curva de respuesta de la variable <i>DEM.Aspect</i> , b) (derecha) Curva de respuesta de la variable <i>Precipitación Media</i>	47
4.13.	Test de Jacknife	49
4.14.	Mapa de favorabilidad ambiental, para el desarrollo del vector. Provincia de Jujuy	50
4.15.	Localidades de la provincia de Jujuy con favorabilidad ambiental, con una rampa de color señalando con rojo la probabilidad mas alta y con azul,la probabilidad nula.	51
4.16.	Localidades de la Eco-región de la Quebrada, con favorabilidad ambiental	52
4.17.	Localidades de la Eco-región de la Puna, con favorabilidad ambiental	53
4.18.	Localidades de la Eco-región del Valle, con favorabilidad ambiental	54
4.19.	Localidades de la Eco-región de las Yungas, con favorabilidad ambiental	55
5.1.	Diseño de un modelo de Riesgo Urbano. Dónde la Amenaza esta dada por la presencia del vector, y la circulación del virus a traves del mapa de los casos humanos, y la Vulnerabilidad esta dada por la densidad de la población. Obtenido desde Porcasi et al. (2012) [3].	60
5.2.	Imagen Landsat 5TM, con un recuadro rojo, señalando la localidad de San Pedro de Jujuy (a) (izquierda). Recorte de la imagen Landsat, sobre la localidad de San Pedro (b) (derecha).	62
5.3.	Imagen LST (banda 6 o térmica de la imagen Landsat). Localidad de San Pedro.	64
5.4.	Imagen DEM. Localidad de San Pedro.	64
5.5.	Imagen NDVI. Localidad de San Pedro.	65
5.6.	Gráficos de Correlación entre las variables: ndsi vs. brillo (izq) y humedad vs. ndwi (der). Salidas del programa estadístico R Studio	66
5.7.	Gráficos de Correlación entre las variables: ndwi vs. ndvi (izq) y verdor vs ndvi (der). Salidas del programa estadístico R Studio	66
5.8.	(Izquierda) Capa shapefile con información del total de la población, desde INDEC 2010. (Derecha) Tabla de atributos de la capa shapefile	67
5.9.	Capa raster (píxel de 30 mts.) transformada desde la capa shapefile de <i>Total de la Población</i>	67
5.10.	Análisis de Regresión Lineal	69
5.11.	Análisis de Regresión Lineal. Total de variables incorporadas en el modelo.	69
5.12.	Análisis de Regresión Lineal. Variables seleccionadas.	70

5.13. Modelo Árbol de Decisión de Riesgo de Dengue, con los nodos de decisión generados en función de las variables predictivas seleccionadas. La imagen sup. muestra las diferentes clases obtenidas, y la inf. de acuerdo a los criterios cumplidos, los 5 tipos de riesgos.	72
5.14. Mapa de riesgo, para la localidad de San Pedro.	73
5.15. Mapa de riesgo, para la localidad de San Pedro, conteniendo una capa vectorial de todos los casos humanos georreferenciados, en forma de cruces de color negro.	73
5.16. Mapa de riesgo, señalando con círculos de color morado, dos zonas de concentración de casos humanos que caen en un área de riesgo bajo-nulo.	74
5.17. Estadísticas de las ROI's de validación sobre el mapa de riesgo. Se consideraron las columnas DN (clases) y los porcentajes.	74
5.18. Mapa de probabilidad, para la localidad de San Pedro.	75

Índice de cuadros

2.1.	Características de la imagen Landsat 5TM	15
2.2.	Características de la imagen Landsat 5TM	15
2.3.	Características de la imagen SPOT 5	16
3.1.	Disposición de los pares según su cercanía espacial y temporal tomada desde “Agregaciones espacio-temporales. Test de Knox.” Federación de Enseñanza de Andalucía (FEA) de CC.OO. 2009	22
4.1.	Contribución de las Variables (Modelo MaxEnt)	48
5.1.	14 Variables Ambientales	68

Quiero dedicar este trabajo de investigación a mi hijo Salvatore Francisco, quién fruto del amor, me ha acompañado durante esta última etapa de concreción de tesis. A mis sobrinitos, Esperanza, Joaquín, Lucas, Martín, Mariam, Jorgelina, Nacho, Fernando, Santiago, Hernan, Belén y al pequeño Francisco.

Que esta tesis, sea un motor que los anime a realizar y luchar siempre por sus sueños, y que logren descubrir que a pesar de las diversas dificultades en la vida, se pueden alcanzar las metas propuestas.

Capítulo 1

Dengue, Situación actual y herramientas geoespaciales como alternativa de control

1.1. Introducción

El dengue es uno de los principales problemas en salud pública en el mundo (Basso et al., 2010 [4]). La Organización Mundial de la Salud (OMS) estima que 80 millones de personas se infectan anualmente, y cerca de 550 mil enfermos necesitan ser hospitalizados, 20 mil mueren como consecuencia de la enfermedad de dengue y más de 100 países tienen transmisión endémica. Durante el año 2008 se produjo una tendencia ascendente de las formas graves de dengue. A finales del mismo año en los países americanos se registraron 854,134 casos, y 584 muertes (tasa de letalidad de 1,5%). La presencia de los 4 serotipos de dengue (DEN 1,2,3,4) circulando en el continente, elevan el riesgo de las formas graves (Eiman et al., 2010 [5]). Los estallidos de dengue han seguido un patrón cíclico, con la ocurrencia de los mayores brotes separados entre sí por períodos de 3 a 5 años, incrementando su importancia con el correr del tiempo (Basso et al., 2010 [4]). En Argentina el dengue reapareció en 1984 y desde 1998 se presenta brotes esporádicos, con casos autóctonos en las provincias de Salta, Jujuy, Formosa, Corrientes y Misiones. El comportamiento de la enfermedad es epidémico y su ocurrencia se restringe a los meses de mayor temperatura (noviembre a mayo). Tiene estrecha relación con la ocurrencia de brotes en los países limítrofes (Estallo et al, 2008 [6]). En el primer semestre del año 2009 se produjo una epidemia de dengue (DEN-1) que desde Salta y Jujuy se extendió hacia el sur y al este, llegando hasta el paralelo 35°. El total de casos confirmados fue de 25.989, en las siguientes provincias Jujuy, Buenos Aires, Catamarca,

Córdoba, Chaco, Entre Ríos, La Rioja, Santa Fe, Santiago del Estero, Tucumán, Salta, Corrientes, Misiones (Lanfri et al., 2011 [7]). Ante este escenario es necesario abordar desde diferentes perspectivas los factores que condicionan la introducción, transmisión y distribución del vector responsable de transmitir la enfermedad de dengue. La Epidemiología Panorámica es capaz de abordar desde un enfoque sistémico e interdisciplinario, el estudio de parámetros ambientales en áreas eco-geográficas donde una enfermedad puede transmitirse (Scavuzzo et al., 2007 [8]). A partir de datos relevados por satélites se puede caracterizar a gran escala los macrofactores que condicionan la reproducción, desarrollo y mantenimiento de un agente patógeno. El principal objetivo es el desarrollo de mapas de riesgo para enfermedades específicas, con el fin de alcanzar la formulación de sistemas de alerta temprana en salud orientando las acciones en los programas de control y prevención de enfermedades (Scavuzzo et al., 2007 [8]).

En este capítulo se describe uno de los principales vectores transmisor de la enfermedad de Dengue, su ecología y biología, su distribución en Argentina y algunos de los factores que influyen en su distribución. La importancia de los recursos disponibles desde el sensoramiento remoto y los Sistemas de Información Geográfica (SIG) como herramientas útiles para los organismos encargados de tomar medidas de control.

1.1.1. La Enfermedad de Dengue

La infección por el virus dengue causa una enfermedad que va desde formas clínicamente inaparentes hasta cuadros graves de hemorragia y shock que en algunas ocasiones, pueden desencadenar con la muerte del paciente. Las primeras manifestaciones clínicas del dengue clásico son de inicio abrupto, tras 2 a 7 días de incubación. Se caracterizan por fiebre elevada (30 °C - 40 °C), cefaleas, mialgias, artralgias, dolor cervical y lumbar, anorexia, gran astenia, náuseas, vómitos y dolor abdominal. Los síntomas respiratorios (tos, rinitis, faringitis) suelen ser frecuentes. Algunos de los aspectos clínicos dependen fundamentalmente de la edad del paciente. Suele estar asociada con gran debilidad física y algunas veces con una convalecencia prolongada (Basso et al., 2010 [4]). En los casos graves, luego de un descenso de la fiebre entre el 3° y el 7° día, el estado del paciente empeora repentinamente, presentándose cianosis, taquipnea, hipotensión, hepatomegalia, hemorragias múltiples y falla circulatoria. Esta situación dura muy poco tiempo, pudiendo llevar a la muerte en 12 a 24 horas, o a la rápida recuperación luego del tratamiento antishock (Chiparelli y Schelotto, 2008 [9]). El virus dengue, pertenece al Grupo: Arbovirus, de la Familia: Flaviviridae, del Género: Flavivirus y presenta los siguientes Serotipos: DEN-1, DEN-2, DEN-3 y DEN-4. Es transmitido por el mosquito *Aedes aegypti* (Diptera, Culicidae), uno de los principales vectores (Descloux et al, 2012

[10]; Vezzani and Carbajo, 2008 [1]) que tiene hábitos domiciliarios, por lo que la transmisión es predominantemente doméstica. La inmunidad es serotipo-específica por lo que la infección con un serotipo determinado confiere inmunidad permanente contra el mismo (inmunidad homóloga), y sólo por unos meses contra el resto de los serotipos (inmunidad heteróloga). El virus se puede encontrar en la sangre de una persona después de los cinco o seis días de haber sido picada por un mosquito infectado, durante este período se manifiestan los primeros síntomas de la enfermedad (Período de Incubación Intrínseco). A partir de este momento, y durante los próximos cuatro o cinco días, el virus queda disponible en la sangre de la persona, para ser transmitido. Las hembras de *Ae. aegypti* son hematófagas diurnas y adquieren el virus cuando se alimentan de una persona en período de viremia (con el virus circulante en su sangre). El virus se replica en el intestino del mosquito y desde ahí migra hacia sus glándulas salivales en las que queda disponible para infectar un humano susceptible a través de una nueva picadura manteniendo la cadena persona infectada-vector-persona susceptible. Todo este ciclo que ocurre en el interior del organismo del mosquito es dependiente de la temperatura ambiente (Eiman et al., 2010 [5]) y se conoce como Período de Incubación Extrínseca y dura de 4 a 10 días. No existe la transmisión persona a persona.

1.1.2. Ecología y ciclo biológico del vector

Luego de alimentarse la hembra de *Ae. aegypti* puede colocar entre 50 y 150 huevos pequeños (0.8 mm). Prefieren recipientes de paredes rígidas, estos suelen estar presentes en las viviendas y su entorno, es por eso que los lugares de cría son fundamentalmente domésticos (Eiman et al., 2010 [5]; Barrera, 2010 [11]).

Aunque los mosquitos se reproducen también en los huecos de los árboles y posiblemente en otras cavidades naturales con agua acumulada, la inmensa mayoría surge en los neumáticos, cubos, vasijas con agua, latas, floreros, pomos y cualquier objeto hecho por el hombre que pueda retener agua. Entre los preferidos suelen estar los recipientes de colores oscuros con cuellos (bocas) anchas, y a la sombra. El agua oscura y la presencia de hojas en descomposición estimulan la postura, pero evitan los recipientes muy contaminados y con olores. La postura la hacen principalmente por la tarde. Los huevos son blancos primero, pero a las dos horas se oscurecen hasta ponerse casi negros (Martínez Torres, 1998 [12]).

Para que los embriones dentro de los huevos se desarrollen completamente y pasen a la fase larval necesitan de dos a tres días con mucha humedad. Los huevos son capaces de resistir la sequía y sobrevivir por períodos que van desde varios meses hasta más de un año. Luego de la etapa de huevo, atraviesa posteriormente por cuatro fases larvales.

Normalmente el desarrollo larval toma cinco a siete días y termina cuando la larva

en la cuarta etapa se desarrolla alcanzando la etapa de pupa que no se alimenta. La transformación de la larva a la forma adulta se completa luego de dos o tres días de la etapa de pupa. El adulto emergente presenta características distintivas, tales como una coloración oscura sobre la que se observan unos diseños de color blanco plateado en forma de lira sobre el tórax y unas bandas blancas alrededor de las patas. Los machos y las hembras tienen los diseños iguales. A las pocas horas de emerger el adulto, se produce el apareamiento entre los mismos (Basso et al., 2010 [4]).

La elevación de la temperatura influye en la duración del ciclo gonadotrófico, en el período de Incubación Extrínseca, así como en el tamaño del propio vector (Basso et al., 2010 [4]). Además si se intensifican las lluvias, aumenta el número de hábitats larvales, y de este modo aumenta a densidad de la población adulta (Martinez Torres, 1998 [12]; Focks et al. 1995 [13]).

En las figuras 1.1, 1.2, 1.3, 1.4 se muestra el ciclo biológico del vector (gentileza del Dr. Carlos Ripoll).



FIGURA 1.1: Huevos de *Ae. aegypti*



FIGURA 1.2: Pupas y Larvas de *Ae. aegypti*



FIGURA 1.3: Vista frontal de un Adulto Hembra de *Ae. aegypti*



FIGURA 1.4: Vista lateral de un Adulto Hembra de *Ae. aegypti*

1.1.3. El Huesped

Se conocen solamente tres tipos de huéspedes naturales para el virus: los seres humanos, los primates y los mosquitos. De éstos sólo los humanos tiene la capacidad de expresar clínicamente la infección.

1.1.4. El dengue en Argentina

En 1916 se produjo el primer brote en Argentina, afectando a las provincias de Entre Ríos y Corrientes, registrándose el ingreso del virus desde Paraguay. En 1964 se logró erradicar a *Ae. aegypti*, gracias a una campaña de control continental organizada por la Organización Panamericana de la Salud; pero hubo una reinfestación a través de la región noreste reportada en 1984 (Boffi, 1998 [14]).

La región Chaco-Salteña experimentó un importante brote en 1998, causado por el

serotipo DEN-2, la evidencia sugiere que el virus fue ingresado desde el Estado Plurinacional de Bolivia. Desde entonces se produjeron una serie de brotes en 1998, 2000, 2002, 2003, 2004, 2006, 2007 y 2008 en diferentes provincias del Noroeste y Noreste de la Argentina (Masuh, 2008 [15]).

Hasta el año 2008, cinco provincias habían presentado casos de dengue autóctonos con la circulación de tres de los cuatro serotipos existentes. Hasta Junio de 2009, la cantidad de provincias con circulación viral autóctona ascendió a 14 (Eiman et al., 2010 [5]).

En la figura 1.5 se muestra la distribución geográfica, propuesta por Vezzani y Carbaajo (2008) [1] de las dos especies de mosquitos del género *Aedes*, potenciales vectores transmisores de dengue (*Ae. aegypti* y *Ae. albopictus*) en las provincias de Argentina.

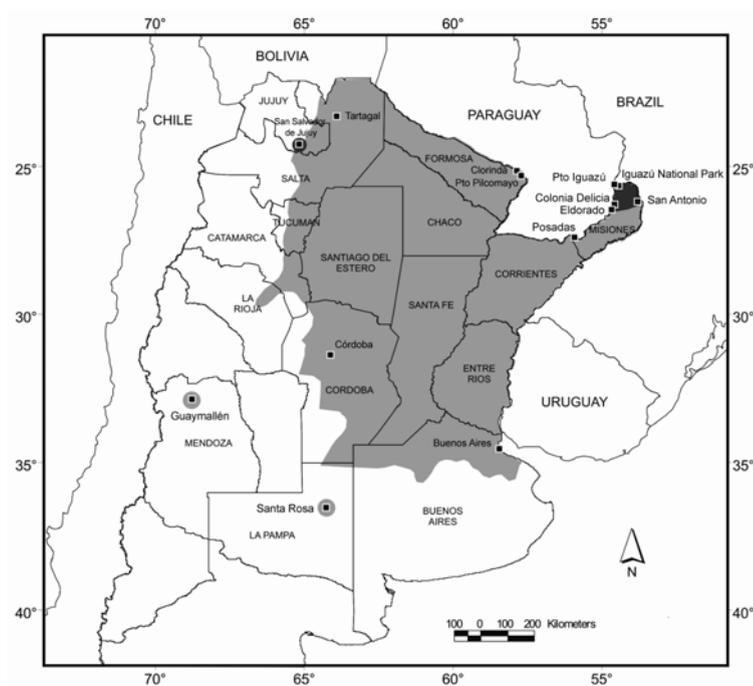


FIGURA 1.5: Distribución geográfica de *Ae. aegypti* (gris claro) y *Ae. albopictus* (gris oscuro) en las provincias argentinas. Extraído de Vezzani y Carbaajo (2008) [1].

1.1.5. Factores ambientales que influyen en el mantenimiento y propagación de dengue y el Sensado Remoto como herramienta en los sistemas de alertas tempranas, para la salud.

Múltiples factores ambientales tanto de carácter bio-geo-físico como sociales constituyen una intrincada trama que condiciona o determina la proliferación del vector-enfermedad. Descloux et al., (2012) [10]: manifiestan que el aumento de viajes y migraciones, fallas en el control de los vectores, y la falta de una vacuna eficaz para prevenir la enfermedad influyen en la propagación del dengue. Los factores bioclimáticos como antrópicos actúan

sobre las poblaciones de insectos, siendo las condiciones climáticas el factor regulador de la distribución espacio temporal de las poblaciones de *Ae. aegypti* y su abundancia. Cambios en el régimen de precipitaciones, en los niveles de humedad o en los valores de temperatura afectan su biología y ecología (Lanfri et al., 2011 [7]). Estallo et al., (2008) [6] sostiene que la transmisión del dengue ocurre en forma particular durante los meses más lluviosos y con altas temperaturas, durante el año. Estas condiciones, en general, propician el desarrollo larval en los hábitats donde se almacena agua (Estallo et al., 2011 [16]; Gubler y Trent, 1993 [17]). Existen además otras variables ambientales influyentes como la vegetación, la elevación del terreno sobre el nivel del mar (Meade et al., 2000 [18]). Todas estas variables ambientales pueden ser medidas desde el Sensado Remoto (SR), para la generación de modelados espaciales y temporales. Inicialmente las investigaciones que empleaban el SR para estudiar las enfermedades sólo realizaban una identificación y elaboración de mapas de hábitats de vectores, o factores ambientales relacionados a la calidad de hábitat del vector (Rogers y Randolph, 1991 [19] and Pope et al., 1992 [20]). Actualmente las investigaciones que involucran SR y técnicas de análisis espacial se centran en identificar y hacer corresponder elementos del paisaje que en conjunto definen la dinámica del vector y la demografía humana relacionada al riesgo de transmisión de una determinada enfermedad (Beck et al., 2000 [21]). La información que brindan los satélites artificiales permiten evaluar la distribución espacial y temporal de riesgo, modelar numéricamente e intentar predecir su comportamiento mediante la generación de sistemas de alerta temprana. Estos factores serán importantes en la toma de decisiones en el contexto de programas de prevención y control de enfermedades (Aguilar y Cruz, 2007 [22]). En este sentido, por ejemplo Cuellar (2014) [23] realizó (mediante un modelo ARIMA) un análisis del grado de influencia de los factores ambientales (cuyas variables fueron obtenidas por SR) 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, en la provincia de Salta.

El Instituto de Altos Estudios Espaciales "Mario Gulich" perteneciente a CONAE (Comisión Nacional de Actividades Espaciales), tiene como uno de sus principales objetivos la generación de Sistemas de Alerta Temprana a Emergencias Ambientales, usando información espacial proveniente de distintos SR (Peralta, 2011 [24]). En el marco de un convenio entre el Ministerio de Salud de la Nación y CONAE en el año 2011 Peralta [24] desarrolló una infraestructura informática para alertas tempranas en materia de prevención y control estratégico de Dengue: el "Sistema de Alerta Temprana y Estratificación de Riesgo de Dengue Nacional y Urbano: SAT/ERDNU". El mismo genera dos productos: un **mapa de riesgo nacional** y un **mapa de riesgo urbano**. La herramienta y su plataforma fue desarrollada para la estimación de riesgo de incidencia y vigilancia de Dengue. Se encuentra disponible operativamente en la siguiente página

web <http://hap.conae.gov.ar/>. La estratificación del Riesgo de Dengue a escala Nacional contempla tres bloques, el primero tiene que ver con la **Caracterización macroambiental**, este bloque está determinado por datos de Temperatura de Superficie, datos de Índice de Vegetación, ambos obtenidos del sensor MODIS, y datos de altura sobre el nivel del mar. Los otros dos bloques **Riesgo entomológico** y **Control vectorial** tienen que ver con las mediciones sobre la densidad de las poblaciones de *Ae. aegypti* y acciones orientadas al control de dichas poblaciones. En la figura 1.6 se muestra el Riesgo Ambiental para el año 2014.

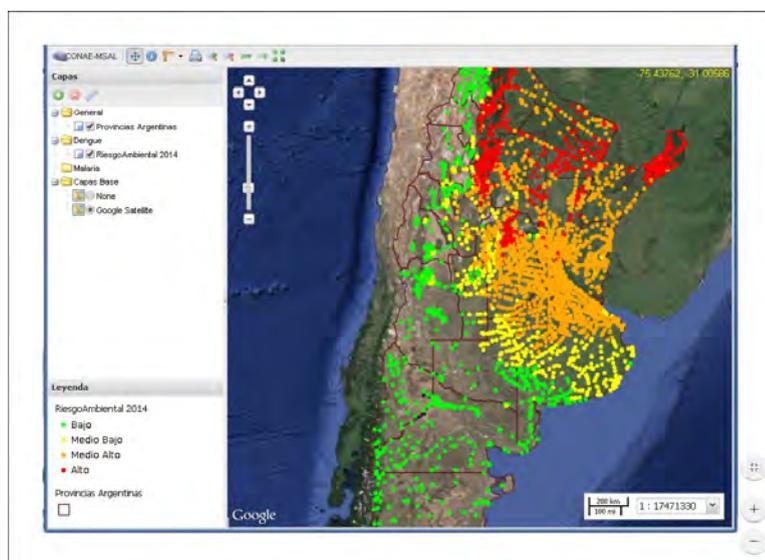


FIGURA 1.6: Componente Riesgo Ambiental estimado para el año 2014. Extraído de Plan Nacional de Prevención y Control de Dengue y fiebre Amarilla. Guía de Usuario ERDNU/HAP [2].

En el año 2012, Quiñonez [25] desarrolló (usando un código libre: C++) un **Algoritmo de estratificación de riesgo de circulación viral de Dengue a nivel urbano-AERDU**, considerando los factores necesarios que se relacionan directamente con el vector, entre ellos:

- Vegetación (el vector vive en lugares con vegetación)
- Humedad (el vector se reproduce en sectores donde hay presencia de agua)
- Suelo (suelo desnudo)

Dentro de los módulos del algoritmo desarrollado se implementa un **Árbol de decisión** que devuelve la imagen predictiva de riesgo de dengue.

1.2. Motivación

En este contexto surge la necesidad de elaborar modelos predictivos de la enfermedad de dengue, que contribuyan a los organismos de salud de la provincia de Jujuy a tomar medidas de acción preventivas y/o mitigadoras. En este sentido, se planteó en este trabajo lo siguiente: “Existen características biofísicas ambientales asociadas con la presencia del vector *Ae. aegypti*, como así también con la transmisión (vector-humano) que pueden identificarse mediante sensores remotos, lo que permitiría identificar áreas de riesgo epidemiológico en determinadas localidades de la provincia de Jujuy”

1.3. Objetivo General

Analizar y explicar la variabilidad geográfica de los patrones de distribución de Dengue en la provincia de Jujuy, teniendo presente el brote de 2009.

1.4. Objetivos Específicos

- Analizar la distribución espacio-temporal de la enfermedad del Dengue, ocurrida en el brote de 2009 en la localidad de San Pedro de Jujuy.
- Analizar que atributos facilitan la proliferación de hábitats del vector, en la provincia de Jujuy y en la localidad de San Pedro, utilizando modelos multivariados basados en datos de campo y variables biofísicas (Temperaturas, Precipitaciones, Coberturas Vegetales, etc) estimadas con sensores remotos.
- Construir mapas de probabilidad de presencia del vector transmisor de dengue.

Capítulo 2

Jujuy y sus Variables Ambientales

2.1. Introducción

Desde la primera mitad del siglo pasado se registra la presencia del vector *Ae. aegypti* en las provincias argentinas de Jujuy, Salta, Formosa, Misiones, Corrientes, Chaco, Santiago del Estero, Tucumán, Catamarca, La Rioja, Santa Fe, Entre Ríos, Córdoba and Buenos Aires (Bejarano, 1979 [26]).

En el año 2009 se produjo uno de los brotes epidémicos más importante de dengue en Argentina, afectando varias provincias, entre ellas Jujuy (Porcasi et al., 2012 [3]).

El control de esta enfermedad requiere el estudio, análisis e identificación de las áreas y los períodos de riesgo, como también la identificación de mecanismos de propagación de virus en un área determinada, para mejorar las estrategias de prevención (Tran et al., 2002 [27]).

Teniendo presente que en la cadena epidemiológica existen tres componentes: patógeno, vector y susceptible, resulta necesario conocer cada uno de ellos, a fin de poder utilizarlos a la hora de construir modelos con información que se puede obtener de los sensores remotos (Rotella et al., 2010 [28]).

Es por eso que en esta unidad se aborda el estudio de las características ambientales de la provincia de Jujuy, la descripción de los datos disponibles desde el Sensado Remoto y de los datos de georreferenciamiento de los casos humanos ocurridos durante el brote de 2009 en la ciudad de San Pedro de Jujuy.

2.1.1. Lugar de estudio: La provincia de Jujuy

Breve descripción Geográfica y Climática

La provincia de Jujuy se ubica en el extremo noroccidental de la República Argentina, encontrándose en ella la más baja latitud del territorio nacional: entre los $21^{\circ} 46'$ en su extremo septentrional y los $24^{\circ} 37'$ de Latitud Sur y entre los $64^{\circ} 10'$ y $67^{\circ} 10'$ de Longitud Oeste, aproximadamente (fig.2.1). De forma muy irregular, alcanza una superficie de 53.219 Km^2 . Limita al norte con el Estado Plurinacional de Bolivia, al oeste con la República de Chile y con la provincia de Salta limita al sur y este.

Cuenta con una subdivisión política de 16 departamentos y una población total de 673307 habitantes.

Los vientos provenientes del Atlántico, portadores de humedad, y el centro de baja presión inducido por las altas temperaturas reinantes en el verano en el centro norte del país, al encontrarse dichos vientos del cuadrante oriental con las sucesivas alturas sobre la precordillera, sufren el proceso de ascenso, condensación y precipitación, que abarca toda el área de las sierras Subandinas y sectores de los cordones más orientales de la precordillera Salto-Jujeña, aunque con las variaciones que impone la altura, es decir, que los montos pueden disminuir si las alturas subsiguientes a aquellas más avanzadas al este no tienen entidad suficiente para provocar la condensación, y viceversa. Los microclima en las laderas o quebradas, se producen según su exposición a los rayos solares y vientos húmedos, encontrándose así vegetación xerófila en las proximidades de selvas tropicales. Durante el invierno se produce una disminución de la temperatura y un aumento consiguiente de la presión, cesando el empuje de los vientos atlánticos, y las lluvias en esta estación son muy escasas. La altitud es un factor que influye en los promedios térmicos (así como junto a la mayor o menor humedad estacional lo hacen sobre las amplitudes térmicas), encontrándose obviamente los mayores promedios anuales en el norte del valle del San Francisco, disminuyendo a medida que ascendemos por las sierras circundantes o que vamos valle arriba. La misma situación termométrica se registra en la quebrada de Humahuaca, que si bien sobre el valle de Jujuy aun llega a los 1000 mm de pluviosidad anual, siempre concentrados en el verano, es arrasada rápidamente por la aridez y sequedad del aire, asociada a mayores amplitudes térmicas. Finalmente, en el altiplano puneño, impera la aridez y sequedad del ambiente. Existen algunas lluvias y granizadas condensadas en las cimas de los cerros, si bien raramente alcanzan los 3200 mm anuales, y concentrados en el verano, se registran algunas nevadas invernales, por otra parte las heladas ocurren casi diariamente. La elevada altura se sobrepone a la latitud tropical, de modo que varía de un clima frío a muy frío en invierno, con una gran amplitud térmica diaria; el elemento climático que más afecta al hombre es el enrarecimiento del aire que

se manifiesta en el llamado mal de Puna o sorocho, debido a la disminución de la presión y del contenido de oxígeno en la atmósfera (DIPEC-JUJUY, 2012. Disponible on line: http://www.dipec.jujuy.gov.ar/idx_anuario/anuario2012.pdf).

La compleja geografía de Jujuy permite identificar cuatro unidades ambientales o regiones, con diferente aptitud: Puna, Quebrada, Valle y Yungas.

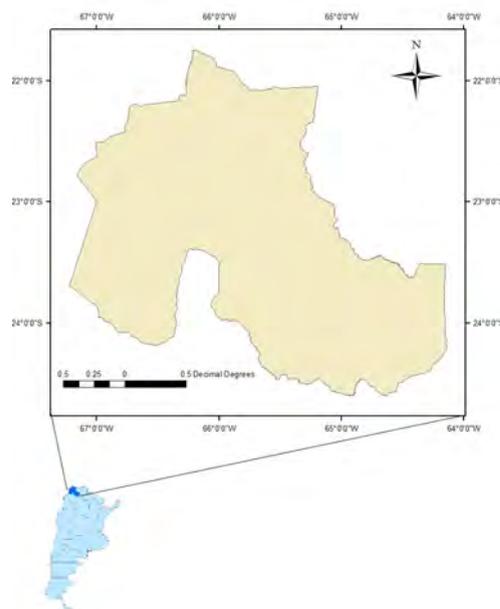


FIGURA 2.1: Figura 2.1. Ubicación Geográfica de Jujuy en Argentina.

2.1.1.1. San Pedro de Jujuy

El departamento de San Pedro se ubica sobre una zona de clima subtropical con estación seca, que favorece el cultivo de la caña, azúcar, tabaco, sorgo, maíz, porotos, frutales, hortalizas y otros cultivos que junto con la cría de ganado vacuno, porcino y caprino constituyen el principal sustento económico de la región. La explotación forestal, es de importancia económica menor, aunque existen gran cantidad de aserraderos en el Parque Industrial de LA URBANA (Zona Sur). El clima tiende a ser cálido la mayor parte del año, pudiéndose observar temperaturas superiores a los 30 °C durante el verano y la primavera y aún en ciertas semanas del otoño y el invierno. Ello se debe a varias razones, entre ellas su baja altitud, su ubicación cercana al Trópico de Capricornio y en especial a la influencia de los vientos cálidos que provienen del norte del país. Durante el invierno las temperaturas oscilan entre los 10 °C y 20 °C, y la presencia de nieve es prácticamente desconocida. Pero en ocasiones y por pocos días las temperaturas mínimas durante dicha estación se acercan a los 0 °C. La localidad de San Pedro de Jujuy cuenta con 60.666 habitantes (INDEC, 2010), y se comunica través de la Ruta Nacional 34 con

la provincia de Salta y la Ruta Provincial 56, une esta ciudad con la ciudad capitalina de San Salvador de Jujuy.

2.1.2. Datos

2.1.2.1. Casos Humanos

- Casos humanos (georreferenciados a nivel de casa) del brote de Dengue ocurrido en la localidad de San Pedro (fig.2.2), en la provincia de Jujuy, durante el año 2009.



FIGURA 2.2: Ubicación Geográfica del departamento de San Pedro en Jujuy, con los casos humanos georreferenciados.

Los datos de casos humanos fueron aportados por el Ministerio de Salud de la provincia de Jujuy. La georreferenciación a nivel de casa de los mismos se llevó a cabo utilizando un GPS.

2.1.2.2. Sitios con presencia de *Ae. aegypti*

- Sitios con presencia del vector (fig.2.3), georreferenciados a nivel de localidad (16 localidades) para los 7 departamentos que a continuación se detallan:
 - Ledesma (Frile Pintado, Yuto, Caimancito, Calilegua y Libertador),
 - El Carmen (Monte Rico, El Carmen, y Perico),
 - San Pedro (San Pedro, La Esperanza y la Mendieta),

- Santa Bárbara (El Talar y Palma Sola),
- Palpalá (Palpalá),
- Dr. Manuel Belgrano (San Salvador de Jujuy) y
- Valle Grande (Valle Grande).



FIGURA 2.3: Ubicación Geográfica dentro de la provincia de Jujuy, de las localidades con presencia del vector.

2.1.2.3. Imágenes Satelitales

Landsat 5 *Thematic Mapper* (L5 TM)

Se seleccionó una imagen L5 TM, desde la página del United States Geological Survey (USGS) <http://earthexplorer.usgs.gov>.

Thematic Mapper (TM) es un sensor a bordo de Landsat 4 and 5, tiene una resolución espacial de 30 m para las bandas 1, 2, 3, 4,5 y 7; mientras que la resolución espacial de la banda 6 es de 120 m. El TM es un escáner multiespectral avanzado diseñado para proveer imágenes de más alta resolución, mejor fidelidad geométrica y mayor exactitud radiométrica respecto al sensor MSS. Las características de la imagen se describen en los cuadros: 2.1 y 2.2.

CUADRO 2.1: Características de la imagen Landsat 5TM

Sensor TM Misión 5	Resolución espectral	Localización espectral nominal	Resolución espacial
Banda 1	0,45 - 0,52	Azul	30 x 30 m
Banda 2	0,52 - 0,60	Verde	30 x 30 m
Banda 3	0,63 - 0,69	Rojo	30 x 30 m
Banda 4	0,76 - 0,90	Infrarrojo cercano	30 x 30 m
Banda 5	1,55 - 1,75	Infrarrojo medio	30 x 30 m
Banda 6	10,4 - 12,5	Infrarrojo térmico	120 x 120 m
Banda 7	2,08 - 2,35	Infrarrojo medio	30 x 30 m

CUADRO 2.2: Características de la imagen Landsat 5TM

Fecha de obtención de la imagen	26 de Noviembre de 2008
Path	231
Row	77
Coordenadas centrales	23° 36' 2.21" LS 66° 32' 27.46" LO

Spot

La imagen SPOT 5, con fecha de adquisición: 03 de Junio de 2013 fue seleccionada desde el catálogo de imágenes de CONAE <http://catalogos.conae.gov.ar/SPOT/>.

Se trata de una imagen multispectral, constituida por cuatro bandas espectrales con una resolución espacial de 10 m, y una banda pancromática cuya resolución espacial es

de 5 m. El nivel de procesamiento es: 2 A. Esto quiere decir que presenta corrección radiométrica y corrección geométrica, realizada en una proyección cartográfica estándar (UTM WGS84 por defecto). Las características se detallan en el cuadro: 2.3.

CUADRO 2.3: Características de la imagen SPOT 5

Bandas	Tamaño de píxel
B1: verde	10 m
B2: rojo	10 m
B3: infrarrojo cercano	10 m
B4: infrarrojo medio (MIR)	10 m
Pancromático	5 m

Productos MODIS

El satélite EOS-AM lleva a bordo el sensor MODIS, por sus siglas en inglés: Moderate Resolution Imaging Spectroradiometer. Este sensor pasivo es un radiómetro que genera imágenes con un scanner óptico de barrido transversal a la superficie terrestre, en 36 bandas que van desde el espectro visible hasta el infrarrojo térmico. La resolución espacial está dada por: dos bandas con una resolución nominal de **250 m**, cinco bandas con una resolución nominal de **500 m** y veintinueve bandas con una resolución nominal de **1000 m** (<http://modis.gsfc.nasa.gov/about/specifications.php>).

Los productos obtenidos desde MODIS fueron Temperatura y Emisividad de la superficie de la Tierra o **LST** por sus siglas en inglés *Land Surface Temperature and Emissivity* e Índice Normalizado de Vegetación o **NDVI** por sus siglas en inglés *Normalize Difference Vegetation Index*. En el anexo 1 se muestra la secuencia de pasos realizados sobre ambos productos, para ser descargados desde el ftp de la página de la NASA (<http://ladsftp.nascom.nasa.gov>).

- Serie temporal de estimaciones de temperaturas medias diarias diurnas, desde MODIS (LST)

Este producto se obtuvo a partir de una serie temporal de todo el año 2008 hasta julio de 2009. Presenta una resolución espacial de 1km. Los productos (MOD11A2)

son Nivel L3, es decir que están georreferenciados y los píxeles contienen un promedio de los valores comprendidos en un período de 8 días. Dichos valores fueron transformados a grados Centígrados (°C).

- Serie temporal de NDVI

Este producto se obtuvo a partir de una serie temporal de todo el año 2008 hasta julio de 2009. Cuenta con una resolución espacial de 250 m y los píxeles contienen los valores máximos de un período de 16 días. Los productos son Nivel L3 (MOD13Q1), es decir que están georreferenciados. Los valores de los píxeles de las imágenes varían entre 0 y 10.000, se implementó un modelo para llevar los valores de los píxeles entre 0 y 1.

Productos desde TRMM

Serie temporal de estimaciones de precipitación obtenidos de la Misión Tropical Rainfall Measuring Mission (TRMM) NASA

Se descargaron productos de precipitación media mensual y acumulada mensual, de todo el año 2008 hasta julio de 2009, con una resolución espacial de 25 km aproximadamente (0.25 grados x 0.25 grados), desde la página http://gdata1.sci.gsfc.nasa.gov/daac-bin/G3/gui.cgi?instance_id=TRMM_Monthly

- Precipitación Media Mensual (PM)
Productos TRMM_3B43.007. Obtenida en *mm/hs*.
- Precipitación Media Acumulada (PMA)
Productos TRMM_3B43_ACC.007. Obtenida en *mm/hs*.

Los productos fueron descargados en formato NetCDF con una cobertura global. Mediante la utilización del software Grid Analysis and Display System (GrADS) se procesaron los archivos, realizando recortes para la zona de interés y transformándolos a un formato GeoTIFF para su posterior utilización.

Productos desde SRTM

- Modelo Elevación del Terreno (DEM)
Este producto cuya resolución espacial es de 90 m. se obtuvo desde la página del SRTM (Shuttle Radar Topographic Mission) de la NASA. <http://www.cgiar-csi.org/> y contiene los valores de las coordenadas geográficas X (longitud) e Y (latitud) y el valor de Z (altura sobre el nivel del mar expresado en metros, para cada píxel).

Productos GlobCover

- Mapa Cobertura de Suelos

Para las distintas coberturas de suelo se recurrió al “Land Cover Product”, del proyecto Glovis GlobCover 2009. Este proyecto consta de un mapa de 22 tipos de coberturas a nivel global (con una resolución de 300 m), realizado a partir de una clasificación automatizada de una serie temporal de MERIS FR (fig.2.4).

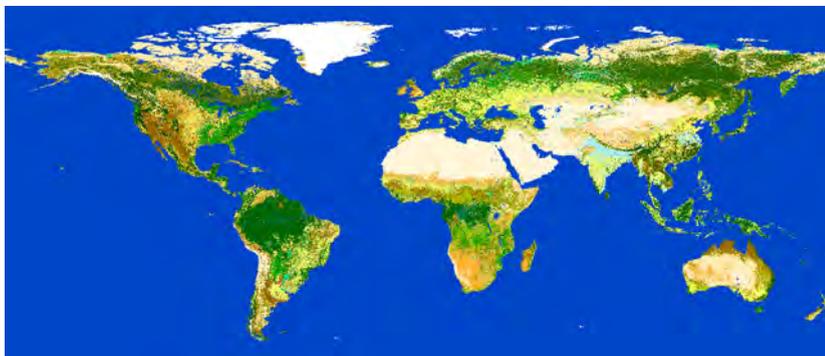


FIGURA 2.4: Mapa mundial de Coberturas de Suelo. Proyecto Glovis GlobCover 2009

La figura 2.5 muestra las referencias del mapa de coberturas de suelo (proyecto Glovis GlobCover 2009).

Value	Label	Red	Green	Blue
11	Post-flooding or irrigated croplands (or aquatic)	170	240	240
14	Rainfed croplands	255	255	100
20	Mosaic cropland (50-70%) / vegetation (grassland/shrubland/forest) (20-50%)	220	240	100
30	Mosaic vegetation (grassland/shrubland/forest) (50-70%) / cropland (20-50%)	205	205	102
40	Closed to open (>15%) broadleaved evergreen or semi-deciduous forest (>5m)	0	100	0
50	Closed (>40%) broadleaved deciduous forest (>5m)	0	160	0
60	Open (15-40%) broadleaved deciduous forest/woodland (>5m)	170	200	0
70	Closed (>40%) needleleaved evergreen forest (>5m)	0	60	0
90	Open (15-40%) needleleaved deciduous or evergreen forest (>5m)	40	100	0
100	Closed to open (>15%) mixed broadleaved and needleleaved forest (>5m)	120	130	0
110	Mosaic forest or shrubland (50-70%) / grassland (20-50%)	140	160	0
120	Mosaic grassland (50-70%) / forest or shrubland (20-50%)	190	150	0
130	Closed to open (>15%) (broadleaved or needleleaved, evergreen or deciduous) shrubland (<5m)	150	100	0
140	Closed to open (>15%) herbaceous vegetation (grassland, savannas or lichens/mosses)	255	180	50
150	Sparse (<15%) vegetation	255	235	175
160	Closed to open (>15%) broadleaved forest regularly flooded (semi-permanently or temporarily) ->	0	120	90
170	Closed (>40%) broadleaved forest or shrubland permanently flooded - Saline or brackish water	0	150	120
180	Closed to open (>15%) grassland or woody vegetation on regularly flooded or waterlogged soil ->	0	220	130
190	Artificial surfaces and associated areas (Urban areas >50%)	195	20	0
200	Bare areas	255	245	215
210	Water bodies	0	70	200
220	Permanent snow and ice	255	255	255
230	No data (burnt areas, clouds,...)	0	0	0

FIGURA 2.5: Referencias del Mapa de Coberturas de Suelo mundial. Proyecto Glovis GlobCover 2009

Capítulo 3

Análisis Espacio-Temporal

3.1. Introducción

En este capítulo se analizó la dinámica de propagación de un brote epidémico de dengue en la ciudad de San Pedro (provincia de Jujuy) en el año 2009. Los casos de dengue notificados fueron georreferenciados a nivel de domicilio del paciente, registrándose también la fecha de inicio de síntomas. La agrupación espacio-temporal de los casos se analizó utilizando conceptos del **Test de Knox**. Este test ha sido ampliamente usado para la detección de clusters espacio-temporal en diversas áreas, veterinaria, epidemiología, etc. (Si, et al., 2008 [29]; Ward et al., 2000 [30]; Rotela et al., 2007 [31]; Fernandez, J. 2014 [32]). Por otra parte, el Índice de Moran empleado por Estallo et al. (2013) [33], permite evaluar el grado de autocorrelación espacial entre diferentes puntos. El rango de este índice varía entre -1 y 1 , los valores cercanos a 0 indican una distribución aleatoria, mientras que valores cercanos a -1 indican autocorrelación espacial negativa y los valores cercanos a 1 indican autocorrelación espacial positiva.

Además se empleó otro método: el análisis del *Vecino más cercano* (en inglés **The nearest neighbour test**) disponible en el software ArcGis 9.3, que siguiendo la línea del Índice de Moran, permite estudiar el patrón de distribución espacial de una serie de puntos.

3.1.1. Análisis Espacio-Temporal

3.1.1.1. Clusters o Agrupamientos

Los “Agrupamientos” o “Clusters” en epidemiología pueden ocurrir tanto en el espacio como en el tiempo, e incluso en ambos. Knox (1964) [34] considera que un cluster es *un*

grupo de concentración de ocurrencias o concentración de eventos, de tamaño suficiente, limitado geográficamente y con baja probabilidad de haber ocurrido por el *azar*. Es decir que el proceso de agrupamiento puede estar influenciado por mecanismos biológicos o sociales, u otras circunstancias. Es importante señalar que el concepto de cluster está relacionado a la escala de medida del análisis. Esto quiere decir que, un cluster puede ser definido a través de cientos de kilómetros y decenas de años o bien en términos de viviendas y períodos semanales. De manera tal que dentro de una pequeña área homogénea, un aparente clúster puede generar una alerta pública, y su causa puede ser identificada más fácilmente que en una escala más grande, dónde los factores que inciden son numerosos, creando diferencias a nivel regional (Marshall, 1991 [35]). El estudio de los clusters resulta de gran importancia cuando existe un único y común mecanismo responsable de la agrupación. La acumulación espacial en un corto período de tiempo puede deberse al proceso de contagio, por lo que resulta de interés investigar el contagio mediante un ensayo de la agrupación en el tiempo y el espacio (Marshall, 1991 [35]). Numerosos tests de interacción espacio-temporal, son usados para evaluar la existencia de agrupamientos o “cluster” en ambas dimensiones. Estos test son frecuentemente aplicados en estudios epidemiológicos, dónde resulta importante saber si los casos de ciertas enfermedades se encuentran más agrupadas que lo esperado, basado en la distribución geográfica subyacente de la población y sobre cualquier otra tendencia exclusivamente temporal (Kulldorff and Hjalmar, 1999 [36]).

3.1.1.2. Test de Knox

Una de las principales técnicas estadísticas ampliamente usada para testear esta interacción fue propuesta por Knox, quién propuso que la mayoría de las definiciones de epidemia se basan en el concepto de una gran variabilidad (no aleatoria) de la incidencia o prevalencia (Knox, 1964 [34]). El test de Knox es un método elegante, simple y efectivo, fácil de usar y calcula de manera sencilla el estadístico de prueba, y requiere el conocimiento de los casos, sin importar los controles. Para ello es necesario conocer la ubicación geográfica y temporal de cada caso, y para cada posible par de casos, se calcula la distancia en términos de espacio y tiempo. Si existen casos *cercanos en el espacio* y también *cercanos en el tiempo*, entonces existe una interacción espacio-temporal (la *cercanía* debe ser definida previamente). Esto podría ser un indicador de que una enfermedad es infecciosa o que es causada por algún otro tipo de agente que aparece localmente en momentos determinados y/o por circunstancias determinadas, como por ejemplo una intoxicación alimentaria (Kulldorff y Hjalmar, 1999 [36]).

En este test, se emplea la fórmula 3.1 para la detección del número de pares posibles de casos:

$$N = n \frac{(n-1)}{2}, \quad (3.1)$$

Donde n es el número total de casos y N es el número de pares posibles de casos.

Aquellos pares de puntos dentro de intervalos de espacio y tiempo especificados (**Clusters** estadísticamente significativos) son contados y comparados con el número de puntos esperados dentro del mismo intervalo.

Se establecen valores umbrales críticos de distancias en espacio y tiempo. Entonces los pares de casos separados por distancias espaciales/temporales inferiores a los críticos, son considerados cercanos en el espacio/tiempo.

3.1.1.3. Desarrollo del método

El estadístico de Knox, prueba una hipótesis nula (H_0) que plantea que el tiempo de ocurrencia de los eventos están distribuidos aleatoriamente a través de la ubicación de los casos, en otras palabras la distancia en el tiempo entre pares de casos son independientes de las distancias espaciales entre pares de casos. Por otra parte, la hipótesis alternativa (H_a): plantea que los casos cercanos en el espacio tienden a estar cercanos en el tiempo. Este método construye dos matrices de dimensiones $n \times n$, siendo n el número de eventos/casos. La primera matriz define las distancias en el espacio, dónde un valor de 1 está asociado con una celda X_{ij} si el evento i ocurrió dentro de una distancia espacial crítica δ del evento j y el valor de 0 en caso contrario. La segunda matriz está definida por las distancia temporales entre cada par de eventos, siguiendo la misma lógica, el valor de 1 está asociado con una celda Y_{ij} si el evento i ocurrió dentro de una distancia temporal crítica τ del evento j y el valor de 0 en caso contrario. Para ambas matrices si $i=j$ el valor en esa celda será de 0. El estadístico de Knox se obtiene mediante el producto cruzado de:

$$R_{\delta\tau} = \sum_{i=1}^n \sum_{j=1}^n X_{ij} Y_{ij}, \quad (3.2)$$

Esto implica que si los pares de eventos no se encuentran dentro de la distancia crítica de tiempo y espacio, entonces $R_{\delta\tau} = 0$. Esto representaría la dispersión substancial espacio temporal del conjunto de datos. Si todos los pares de eventos se encuentran dentro de la distancia crítica temporal y espacial, entonces $R_{\delta\tau}$ será igual al número de pares de eventos. Esto representa el máximo cluster espacio-temporal posible del set de datos. Normalmente los valores observados de $R_{\delta\tau}$ caerán entre esos dos extremos, luego el

valor observado es comparado con un valor esperado para determinar la significancia del resultado (Eckley y Curtin, 2013 [37]).

Para calcular la **distancia espacial** entre dos casos (X_i, Y_i) y (X_j, Y_j) se utiliza la distancia Euclídea:

$$e_{ij} = +\sqrt{(X_i - X_j)^2 + (Y_i - Y_j)^2} \tag{3.3}$$

La **distancia temporal** se calcula haciendo la diferencia, en valor absoluto, entre las fechas de ocurrencia de los dos casos:

$$t_{ij} = |f_i - f_j| \tag{3.4}$$

A partir de estos valores se clasifican los pares de casos en una tabla (Cuadro 3.1) de doble entrada (2x2), según las cuatro posibilidades que existen descritas a continuación:

- $A \implies$ Pares cercanos en tiempo y espacio,
- $B \implies$ Pares de casos cercanos sólo en espacio,
- $C \implies$ Pares de casos cercanos sólo en tiempo,
- $D \implies$ Pares sin cercanía de ningún tipo.

CUADRO 3.1: Disposición de los pares según su cercanía espacial y temporal tomada desde “Agregaciones espacio-temporales. Test de Knox.” Federación de Enseñanza de Andalucía (FEA) de CC.OO. 2009

		Cercanos en el Tiempo		
		$\leq \delta$	$> \delta$	Total
Cercanos en el espacio	$\leq \tau$	A	B	A+B
	$> \tau$	C	D	C+D
Total		A+C	D+B	n=A+B+C+D

El criterio de proximidad en cada dimensión se define teniendo en cuenta la distancia espacial crítica e y la distancia temporal crítica t :

- (A) Pares cercanos en tiempo y espacio: $e_{ij} \leq e$ y $t_{ij} \leq t$
- (B) Pares cercanos sólo en espacio: $e_{ij} \leq e$ y $t_{ij} > t$
- (C) Pares cercanos sólo en tiempo: $t_{ij} \leq t$ y $e_{ij} > e$
- (D) Pares sin cercanía de ningún tipo: $e_{ij} > e$ y $t_{ij} > t$

3.1.1.4. Requerimientos para su aplicación

Es necesario disponer previamente de los siguientes datos:

- Las coordenadas espaciales X e Y correspondientes a cada uno de los casos de enfermedad ocurridos durante el período de estudio. Estas coordenadas se expresan en un sistema de coordenadas planas en el sistema de proyección Gauss Krüger.
- Las fechas de ocurrencia de los casos (en días julianos).
- Definición de los dos valores críticos e y t , los cuales constituyen, respectivamente, la distancia máxima aceptada entre dos casos para que puedan ser considerados cercanos espacialmente (distancia espacial crítica) y el tiempo máximo entre la ocurrencia de dos casos para considerarse próximos en tiempo (distancia temporal crítica).

3.1.1.5. Las limitaciones del método Knox

- El método no indica dónde se encuentran los clusters, sino sólo se limita a responder si existen o no.
- Este método es parcial cuando la población geográfica cambia.
- El criterio de significación del método está basado en la interacción espacio–tiempo, por tanto no es sensible para detectar clusters en una sola de estas dimensiones.

3.2. Metodología

Se emplearon los datos referidos a los casos humanos provenientes de la **Localidad de San Pedro**, durante el brote del año 2009.

3.2.1. Descripción de los datos

Se dispuso de un total de 216 casos humanos, georreferenciados usando un Sistema de Posicionamiento Global (GPS). En la figura 3.1 a, se observa la distribución geoespacial de los casos. Las coordenadas geográficas (WGS-84), fueron transformadas a coordenadas planas usando el Marco de Referencia Geodésico Nacional POSGAR 94. Es importante resaltar que para la ubicación geoespacial de los casos de dengue, se tuvo en cuenta el domicilio de residencia que, aunque no implique que los pacientes hayan contraído en sus viviendas la enfermedad, es la manera más adecuada para aplicar un criterio de localización, debido a que hay un mayor riesgo de infección con dengue en las viviendas teniendo en cuenta el comportamiento endofílico de los mosquitos (Tran et al., 2004 [38]).

Posteriormente se armó una matriz de tres columnas, en cuyo interior se dispusieron las coordenadas planas (en X e Y) y la fecha de notificación de Inicio de Síntomas para cada caso, transformadas previamente en días julianos.

Para determinar si la distribución de los casos responden al azar o bien siguen un patrón determinado por el ambiente, fue necesario generar una serie de datos aleatorios, en ambas dimensiones: espacio y tiempo, para ser comparados. Es importante resaltar que la disposición de los casos responden a la geomorfología de la ciudad, por cuanto se resolvió que para generar los casos aleatorios, estos debían responder a la misma geomorfología de la ciudad, es por eso que se georreferenciaron todas las manzanas de la localidad (figura 3.1 b). Y a partir de este nuevo set de datos se extrajeron de manera aleatoria 216 puntos para ser comparados con los casos reales.

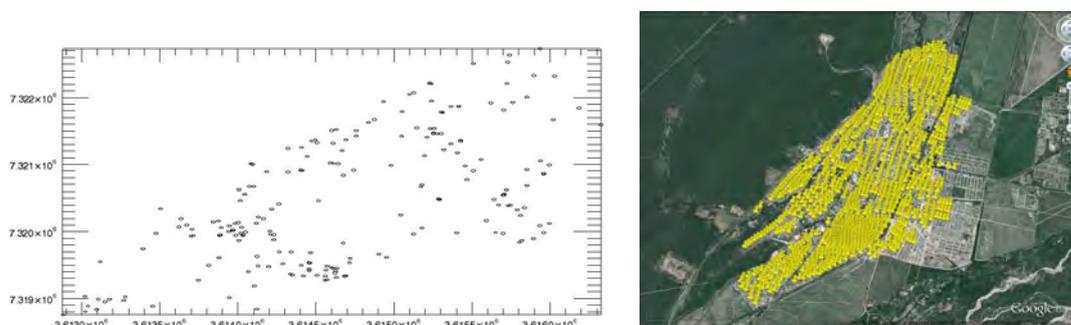


FIGURA 3.1: a) (izquierda) Distribución espacial de los casos humanos de dengue en 2009, en la localidad de San Pedro. Representación gráfica desde el lenguaje de programación IDL, b) (derecha) Ubicación y distribución espacial de las manzanas de la localidad de San Pedro, en 2009. Imagen desde Google earth.

3.2.2. Análisis de Clusters Espacio-Temporal

3.2.2.1. Aplicación del Test de Knox

Se ejecutó el código de análisis espacio-temporal de Knox, implementado en el lenguaje de programación IDL, desarrollado por el Lic. en Física Mario Lanfri, el Dr. Marcelo Scavuzzo y la colaboración del Dr. Camilo Rotela, en el marco de la tesis de Doctorado "*Desarrollo de Modelos e Indicadores Remotos de Riesgo Epidemiológico de Dengue en Argentina*" del Dr. Camilo Rotela (2013) [39].

A este código se le incorporó una fuente de datos (consistida por las georreferencias del centro de cada una de las manzanas de la ciudad), para que el programa seleccione aleatoriamente 216 puntos, para ser comparados luego con la distribución de los casos reales. Se corrieron 1000 iteraciones, siguiendo lo propuesto por Barton and David (1966) [40] de la implementación del método de Monte Carlo, para aumentar la cantidad de escenarios con eventos producidos aleatoriamente, para así compararlos con el escenario real.

Los valores umbrales críticos de tiempo y espacio fueron:

- Tiempo crítico: 1 día
- Distancia crítica de 50 m.

Aplicando la ecuación 3.1, se obtuvo un total $\Rightarrow N=23220$ combinaciones posibles para los pares de casos a comparar.

En la figura 3.2 se muestra la superposición de los histogramas correspondientes a la distribución de los pares de casos según el espacio (Reales vs. Azar). Sobre el eje X se disponen las distancias espaciales para cada par de casos, desde la mínima hasta la máxima distancia que es de 5000 m, con cortes de 250 m. Sobre el eje Y se ubica la frecuencia de los pares de casos posibles.

Se observa que la curva tanto de las distancias entre los pares de casos reales como la de los generados aleatoriamente asciende progresivamente hasta alcanzar la distancia de 1500 m aproximadamente, sobre el eje X . Luego ambas curvas experimentan una caída, de manera tal que mientras aumenta la distancia espacial entre los pares de casos, por encima de los 1500 m, la frecuencia de los mismos disminuye. La curva de color oscuro (negro) corresponde a la distribución de las distancias entre los pares de casos reales, mientras que la más clara (gris) corresponde a la distribución de las distancias de los pares de casos generados aleatoriamente por el programa. La curva de los casos reales

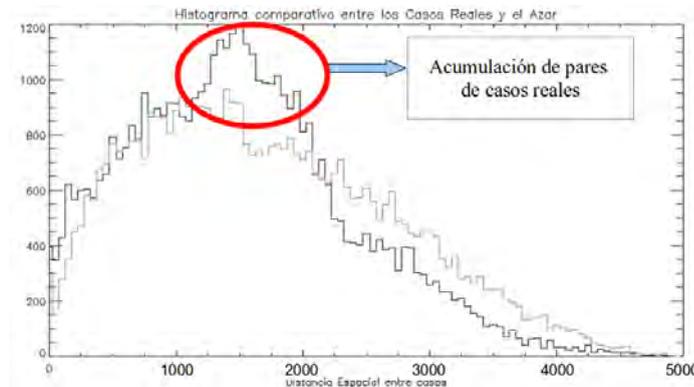


FIGURA 3.2: Histograma Comparativo de la distribución espacial de los casos reales vs. el azar.

manifiesta una acumulación de pares de casos ubicados a una distancia entre los 1250 y 2000 m , aproximadamente. Distinguiéndose de la curva de los casos aleatorios.

La figura 3.3 muestra la superposición de los histogramas correspondientes a la distribución de los pares de casos según el tiempo. Sobre el eje X se disponen las distancias temporales, desde el día 1 hasta el día 80, con cortes de a 5 días. Sobre el eje Y se ubica la frecuencia de los pares de casos posibles, dispuestos a una determinada distancia temporal. Ambas curvas tienen un crecimiento abrupto, hasta alcanzar una distancia temporal de 10 días aproximadamente, a partir de este punto, ambas experimentan una caída, de manera tal que mientras aumenta la distancia temporal entre los pares de casos, la frecuencia de los pares de casos disminuye. La curva de color negro corresponde a la distribución de los pares de casos reales según el tiempo, mientras que la de color gris corresponde a la de los generados al azar. Es posible distinguir una acumulación de pares de casos, correspondiente a la curva de los casos reales, hasta una distancia igual a 25 días aproximadamente, que supera a lo esperado para los casos aleatorios.

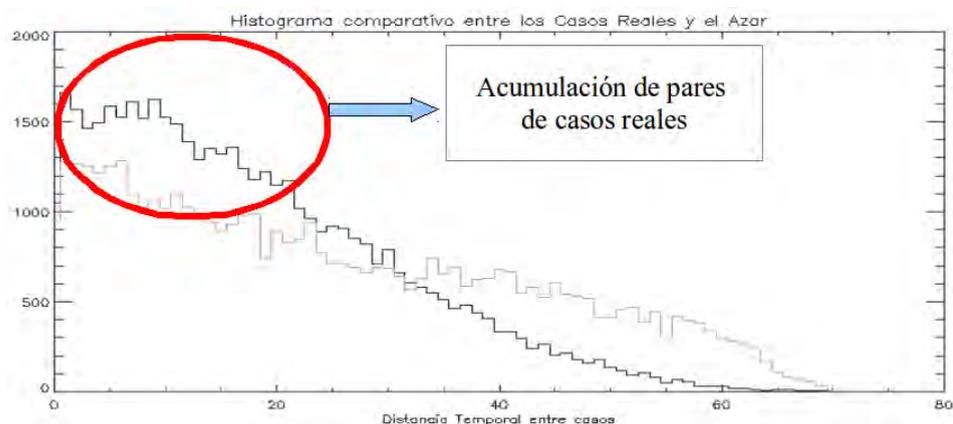


FIGURA 3.3: Superposición de los histogramas de los casos reales y los generados aleatoriamente, distribuidos en el tiempo (a diario).

La distribución de los casos reales para cada par de distancias (figura 3.4) mostró la existencia de 3 agrupamientos principales, al considerar la interacción de las dos dimensiones. El primer grupo (I) se encontró entre los 20 días y 300 m. de distancia. El segundo grupo (II) a una distancia de aproximadamente 10 días y 750 m. y un tercer grupo (III) con una importante densidad, a una distancia de 1500 m, con radio de dispersión de 500 m. aproximadamente y a una distancia temporal de 20 días.

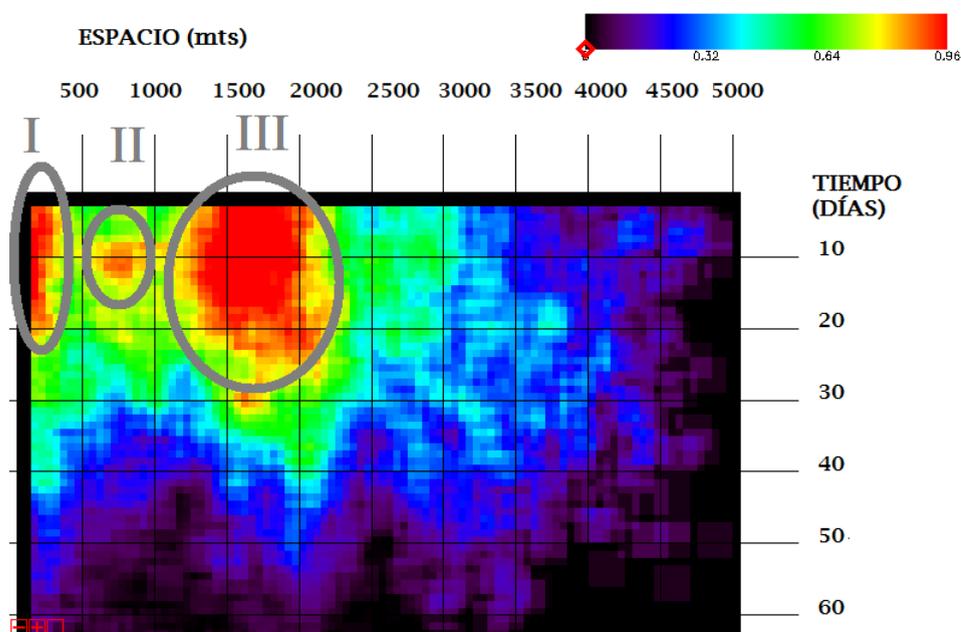


FIGURA 3.4: Representación gráfica del patrón de distribución en el espacio (en metros) y tiempo (en días), de pares de casos de dengue, formando clusters. Cada píxel representa 50 m de distancia espacial y 1 día, los cortes están hechos cada 10 píxeles.

3.2.2.2. Aplicación de técnicas de Autocorrelación Espacial

Se realizó un análisis de la distribución espacial de los casos, usando herramientas desde Arc Gis 9.3.

Índice de Moran

Spatial Autocorrelation (Global Moran's I), mide la autocorrelación en el espacio de los datos, dada la ubicación geográfica y atributos de los mismos, a través del método de la distancia Euclídea (fig. 3.5). Aquí se observó que el patrón de distribución es agregado, con un nivel de significancia del 0.05.

Cociente entre Distancia media observada y la Distancia media esperada

Esta técnica como la anterior, mide la autocorrelación espacial (fig. 3.6), y también se

observó que el patrón de distribución de los pares de casos es agregado, con un nivel de significancia del 0.01.

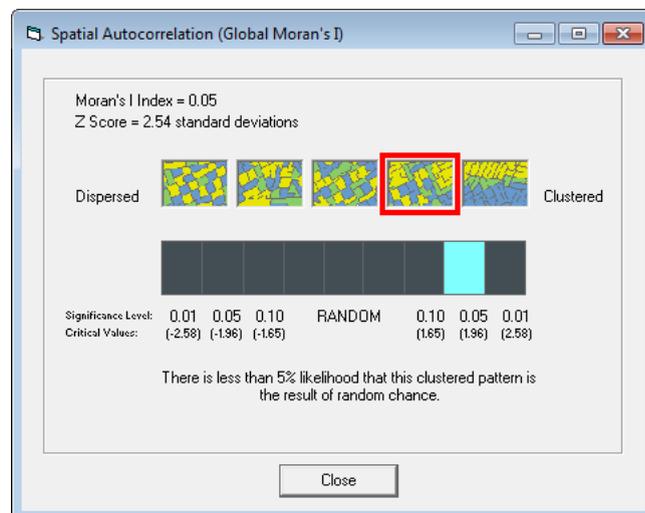


FIGURA 3.5: Autocorrelación espacial (Moran's I) de los casos reales. Salida de ArcGis 9.3

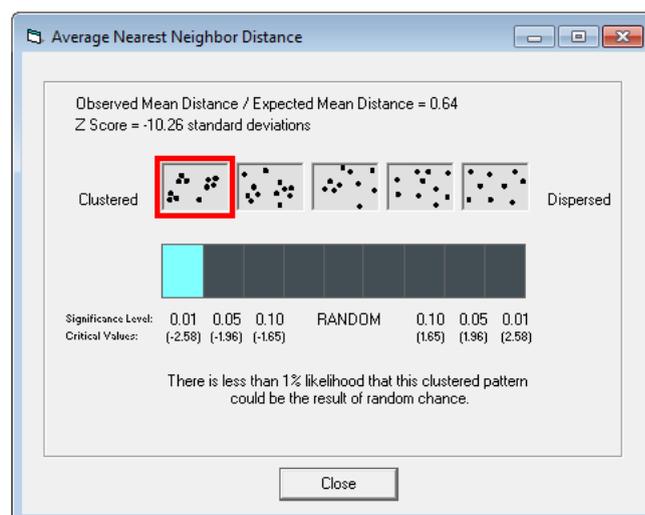


FIGURA 3.6: Cociente entre la Distancia media observada y la Distancia media esperada, de los casos reales. Salida de ArcGis 9.3

3.2.2.3. Density Kernel

La herramienta *Density Kernel* emplea un algoritmo capaz de calcular la densidad de puntos para cada celda de la capa raster de salida a partir de la función núcleo (kernel), creando una superficie continua. Es necesario establecer un "Radio de Búsqueda", que se interpretará como el área de influencia máxima de cada punto. Se asume un área de influencia circular y la misma decrece a medida que aumenta la distancia al punto, haciéndose cero en el radio de búsqueda (Rotela et al., 2007 [31]).

Esta herramienta permite visualizar la distribución de los clusters en el espacio, como se observa en la figura 3.7 (izquierda). Es posible distinguir dos importantes clusters con alta densidad de casos en un radio de búsqueda de 100 m. Cuando la distribución de los clusters se superpone sobre una imagen de la ciudad (fig. 3.7 derecha), de esta manera se podría conjeturar acerca de los posibles factores ambientales/antropogénicos que incidieron en el desarrollo de dichos clusters. La gradación de colores del amarillo al azul señala la densidad de los clusters de mayor a menor, respectivamente.

La imagen de alta resolución espacial empleada en este punto fue una Spot 5, cuyas características fueron descritas en el Capítulo 2. Ya que la misma cuenta con una banda Pancromática de alta resolución espacial, se realizó un *Pan-Sharpening*, que es un merge de bandas multispectrales y pancromática, usando la herramienta desde ENVI 4.7 (*Image Sharpening*) para obtener una mejor resolución espacial.

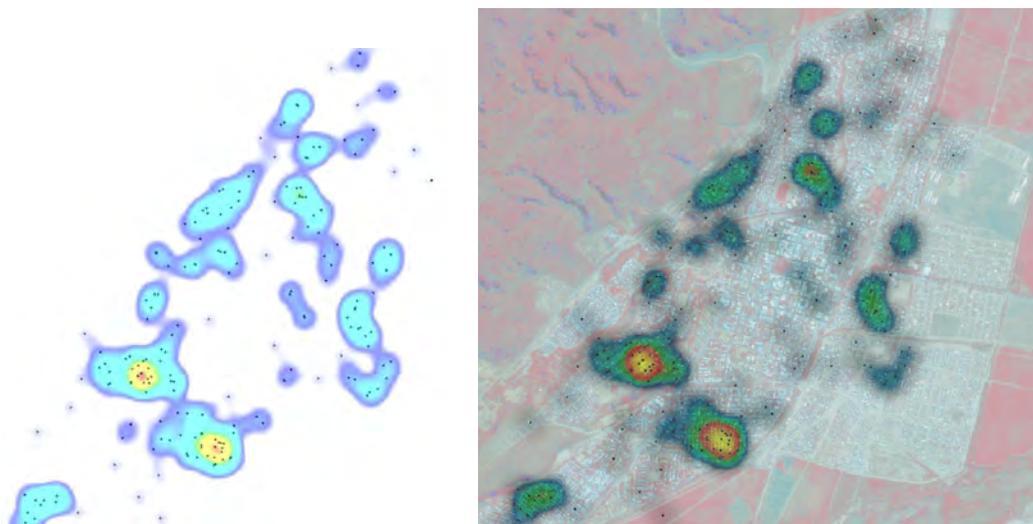


FIGURA 3.7: (izquierda) Density Kernel. Con un radio de búsqueda de 100 m, la salida del algoritmo muestra la distribución de los clusters dispuestos en la ciudad de San Pedro. (derecha) Superposición de la distribución de los clusters sobre una imagen SPOT de alta resolución espacial.

Los clusters con alta densidad ubicados en el acceso sur de la ciudad, además se encuentran cercanos a las avenidas principales (Avenida Siria y Avenida Uruguay) que derivan de la ruta 56 (en el sur de la ciudad, ver figura 3.8).

Se observan otros clusters de menor densidad, uno ubicado mas al sur de la ciudad de San Pedro, y otros seis clusters distribuidos al este, norte y oeste de la ciudad.

Sucesión espacio temporal del brote

A continuación se muestra en las figuras 3.9 y 3.10 cómo fue la sucesión espacio temporal del brote de 2009 en la ciudad de San Pedro de Jujuy, desde la primer semana hasta la última.

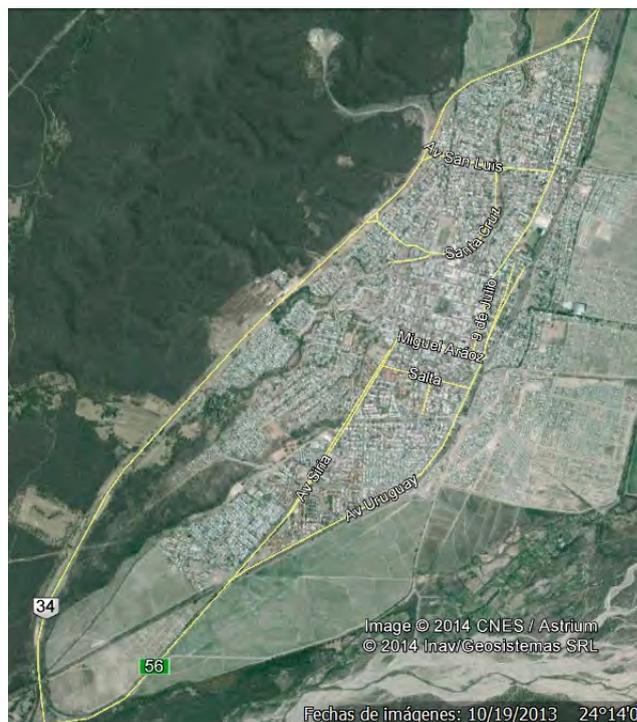


FIGURA 3.8: Ciudad de San Pedro de Jujuy, con sus calles principales. Imagen obtenida desde Google Earth.

3.3. Discusión

Un primer estudio para comprender la dinámica de propagación del brote de dengue ocurrido en 2009 en la ciudad de San Pedro de Jujuy, es el análisis del patrón de comportamiento de la enfermedad. Uno de estos análisis es el test de Knox que, como lo han descripto Knox, (1964) [34]; Si, et al., (2008) [29]; Rotela et al., (2007) [31]; Fernandez, (2014) [32], permite analizar y descubrir agrupamientos de casos tanto en el espacio como en el tiempo. En este estudio se reveló la existencia de casos distribuidos de forma agregada y no azarosa. Se observaron patrones espaciales muy definidos y agrupamientos a grandes distancias (en un período de 20 días, la dispersión de los pares de casos alcanzó los 2000 m de distancia), esto probablemente se deba a los hábitos de la población (falta de actividades preventivas como por ejemplo el descacharrado). Como sostuvo el Dr. Ripoll en una entrevista (2014): una vez iniciado el brote de 2009 en la provincia de Jujuy, fue difícil controlarlo, ya que hubieron momentos en los que 23 localidades presentaban notificación de casos humanos; teniendo presente las limitaciones en cantidad de personal, vehículos y máquinas del Ministerio de Salud de la Provincia de Jujuy, para el control del mismo.

El análisis de Autocorrelación de Moran I, indicó que el patrón de distribución de los casos es agregado. Los resultados son coincidentes con los hallazgos realizados por Ward

et al. (2000) [30] quienes demostraron que para el set de datos analizados, los test de Knox y Nearest Neighbour resultaron significativos en la detección de clusters.

Con la herramienta *Density Kernel*, se observó que la distribución de los clusters de alta densidad están cercanos a las principales vías de acceso de la ciudad. Esto podría coincidir con los resultados obtenidos por Rotela et. al (2007) [31] para el brote de Dengue Clásico en la ciudad de Tartagal, en la provincia de Salta, en 2004, ya que las rutas son una de las principales vías a través de las cuales se dispersa la enfermedad. Esta transmisión está altamente asociada con el perfil entomológico de *Ae. aegypti*, epidemiológico y cultural (la llegada de personas infectadas a los sectores involucrados inicia los brotes). Patz et al. (1998) [41] encontraron que en regiones hiperendémicas la transmisión de dengue se produce en gran medida por los patrones de migración humana.

3.4. Conclusión

La aplicación del test de Knox permite mediante un análisis comparativo en espacio y tiempo, descubrir la presencia de patrones o clusters de distribución de la enfermedad. Para los casos estudiados, se evidenció la presencia de esta distribución en grupos y su diferenciación de los patrones aleatorios, por cuanto es posible pensar que la distribución responde a condiciones externas, que pueden ser del ambiente geográfico, biológico, sociocultural, etc. Los patrones encontrados, podrían estar relacionados con factores entomológicos, eco-epidemiológicos y de intervención vectorial. La herramienta **Density Kernel**, resultó de gran utilidad ya que genera una gráfica con la densidad de puntos (casos) para un determinado radio en el espacio.

Cabe destacar que la distribución observada de los casos esta sujeta a la fecha de inicio de síntomas de los mismos. Los resultados obtenidos evidencian el uso potencial de Sensores Remotos y Sistemas de Información Geográfica en las estrategias de control del dengue, y revela la necesidad de generalizar este tipo de estudio de los brotes de otros eventos, mientras esté disponible un preciso sistema de georreferenciamiento para el lugar de estudio. La metodología y las herramientas desarrolladas en este trabajo podrían ser implementadas para simular los ciclos espacio-temporales de brotes en zonas donde no hay datos disponibles sobre el terreno.

Las herramientas empleadas en esta unidad podrían contribuir al estudio y análisis de otros brotes de dengue en otras localidades, a fin de poder comprender mejor el comportamiento dinámico de la enfermedad durante un brote en un lugar donde las condiciones macroambientales y microambientales están dadas.

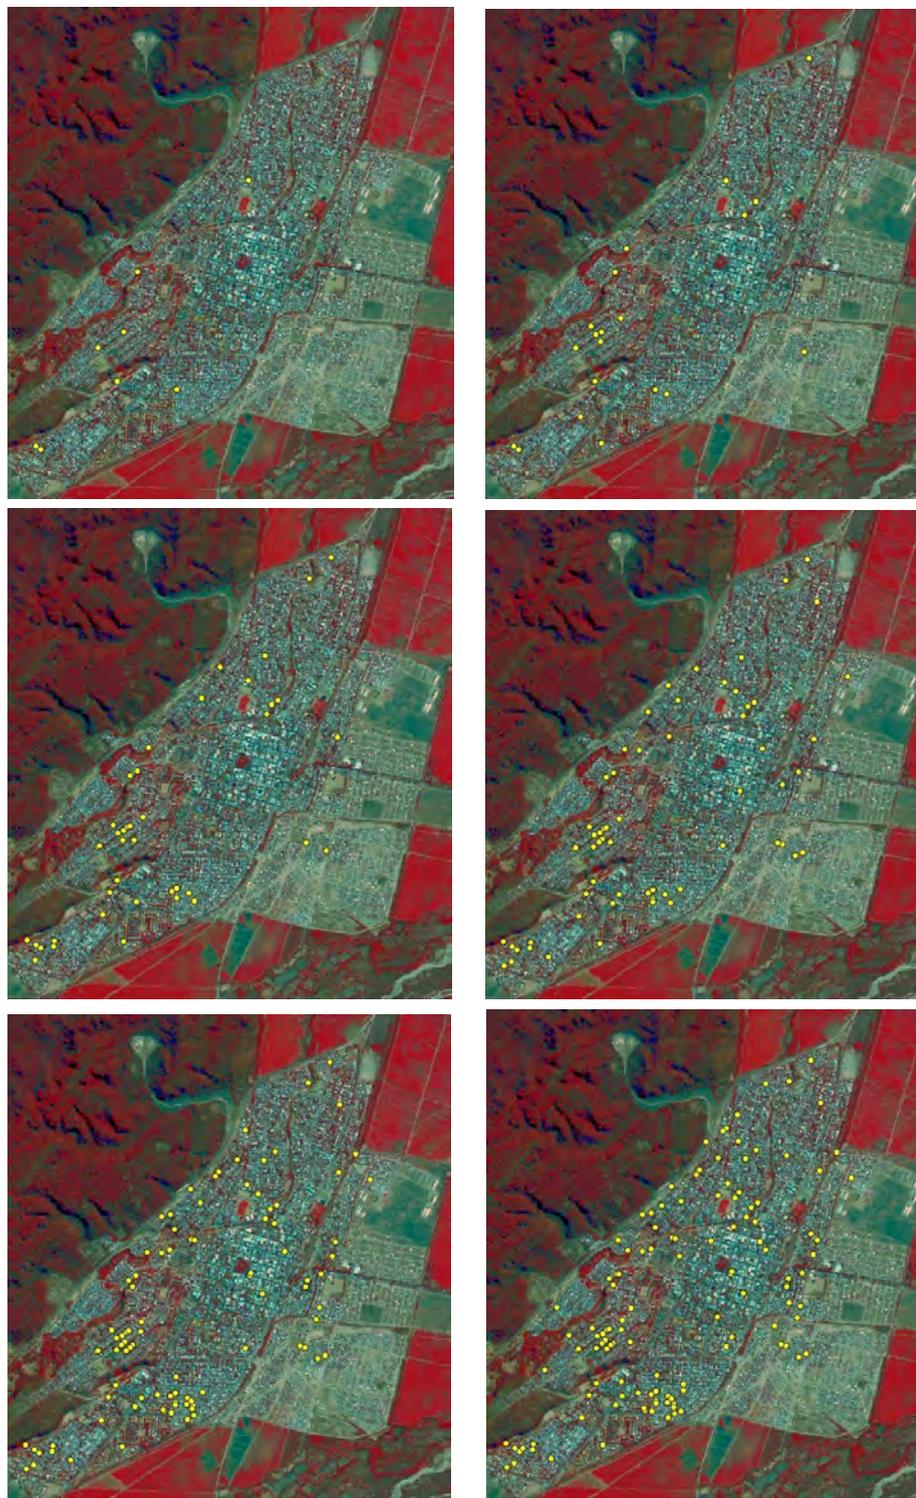


FIGURA 3.9: Secuencia cronológica, por semana (Semana 1 a 6, de izquierda a derecha y de arriba hacia abajo), del brote de dengue en 2009, en la localidad de San Pedro.

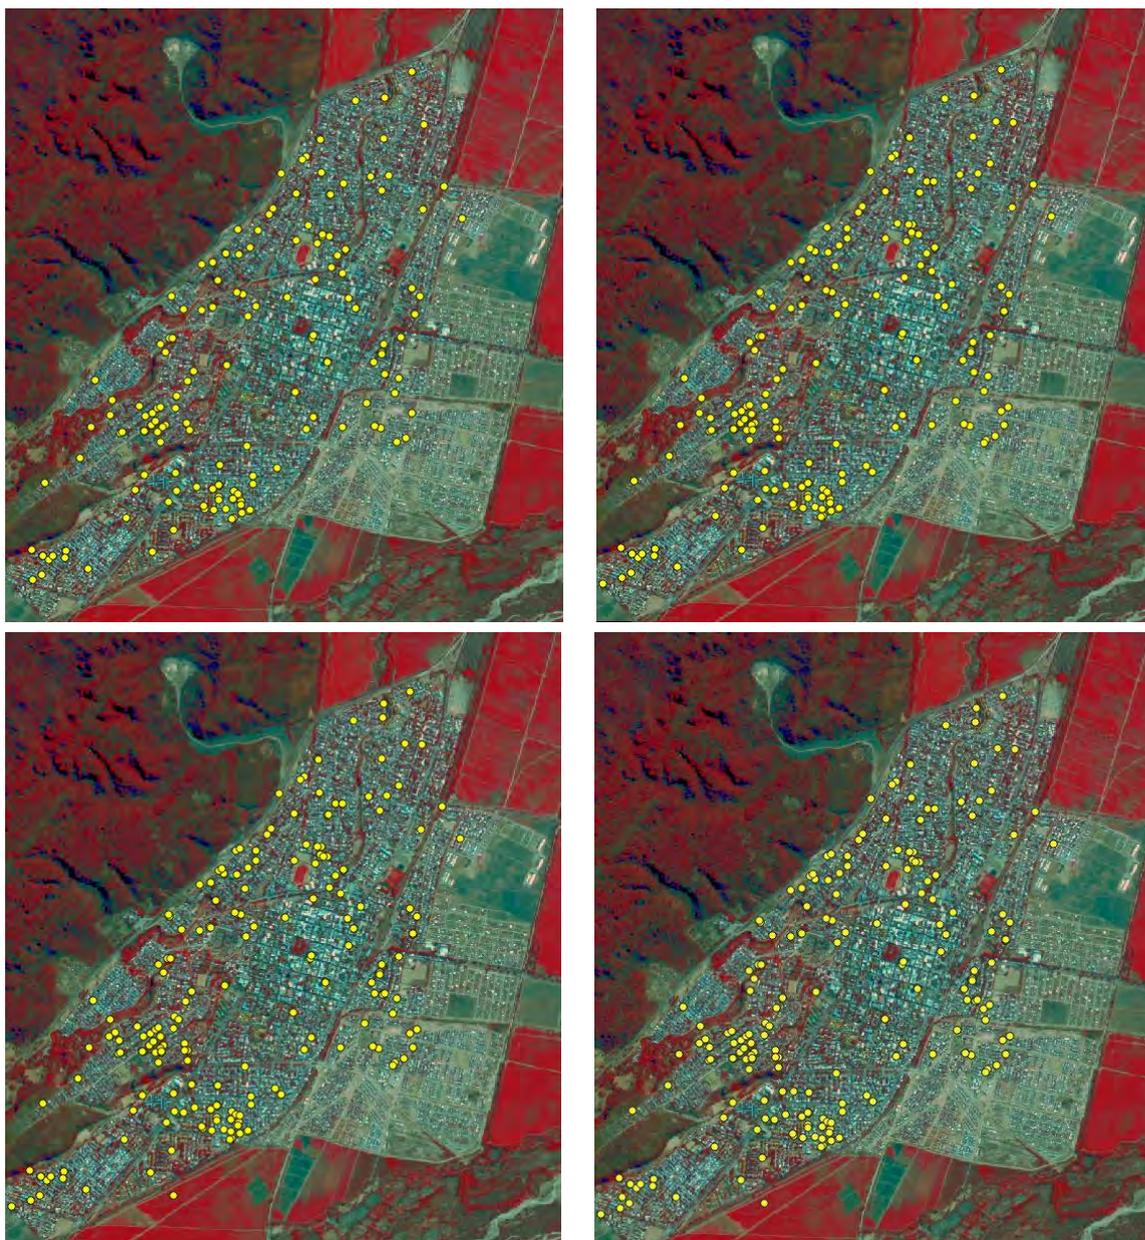


FIGURA 3.10: Secuencia cronológica, por semana (Semana 7 a 10, de izquierda a derecha y de arriba hacia abajo), del brote de dengue en 2009, en la localidad de San Pedro.

Capítulo 4

Modelos predictivos de Dengue (I)

4.1. Introducción

La presencia, densidad y extensión geográfica del vector son componentes principales que determinan entre otros factores la transmisión viral y frecuencia de la enfermedad del dengue (Karim et al., 2012 [42], Basso et al. 2010 [4]). Actualmente el único método disponible de prevención y control de dengue implica combatir el vector en sus estadios larval y adulto, hasta tanto se desarrolle la vacuna contra el dengue (Reiter et al. 2003 [43], Guzman, et al 2006 [44]). En este sentido este capítulo aborda un modelado de presencia de *Ae. aegypti*, generando mapas de Favorabilidad Ambiental para el vector a escala provincial, usando el modelado de Máxima Entropía (MaxEnt) a partir de variables biofísicas y climáticas derivadas de imágenes satelitales. Esto constituye una herramienta complementaria para poder implementar un programa completo de monitoreo a nivel provincial, como lo es el SAT/ERDNU (Peralta, 2011 [24]).

4.1.1. Modelado para *Ae. aegypti*

Los Modelos de distribución de especies, estiman la relación entre el registro de las especies en un sitio dado y las características espaciales y/o ambientales de dicho sitio (Franklin, 2010) [45]. El modelado del nicho ambiental se basa en el principio de que la distribución estimada de una especie debe coincidir con la distribución conocida o deducida a partir de las condiciones ambientales dónde ha sido observada. El procedimiento consiste en usar algoritmos computarizados para generar mapas predictivos sobre la distribución potencial de especies en el espacio geográfico a partir de las distribuciones

(conocidas o deducidas) de la especie en el espacio ambiental. Los modelos de distribución de especies tienen un gran interés aplicado ya que permiten evaluar cuantitativamente la posibilidad de que la población de una especie dada ocupe un determinado lugar. Las condiciones macroambientales delimitan la distribución y abundancia de *Ae. aegypti* (Focks et al., 1993 [46]). Es por eso que se han desarrollado diversos modelos (en general modelos de regresión multivariados) incluyendo variables ambientales, obtenidas desde el Sensado Remoto y variables meteorológicas que mejor estiman la presencia y actividad del vector. La temperatura es una de las principales variables ambientales reguladoras de la dinámica poblacional del vector (Dominguez et al., 2000 [47]; Rose et al., 2000 [48]; Focks et al., 1993 [46]; Rueda et al., 1990 [49]), debido a que se asocia a la modificación de las tasas (velocidades) de desarrollo de los estados inmaduros (Otero et al., 2006 [50]). Además la temperatura acorta el período de incubación extrínseco (PIE), de manera que en poco tiempo el virus está disponible para ser transmitido por el vector en una nueva infección (Karim et al., 2012 [42]. En este sentido Vezzani et al. (2004) [51] encontraron que la transmisión del virus de dengue coincide con los meses de verano. Nakhapakom and Tripathi (2005) [52] observaron que la incidencia de dengue en Tailandia durante el brote de 2008 sucedió cuando la temperatura promedio aumentó por encima de la normal registrada. Por otra parte los modelos desarrollados por Gharbi et al., (2011) [53] mejoraban la predicción de dengue cuando se incorporaba la variable temperatura. Existe un umbral óptimo en el que se desarrolla el ciclo (Zambrano et al., 2012 [54]; Rotela et al., 2007 [31]). Cabe resaltar además que las condiciones de humedad ambiental y precipitaciones resultan necesarias para generar los lugares de cría de los estadios iniciales del vector (Zambrano et al., 2012 [54]; Kiang et al., 2012 [55]; Estallo et al., 2012 [56]; Estallo et al., 2008 [6]; Patz et al., 2006 [57]; Hales et al., 2003 [58]). De acuerdo a los estudios llevados a cabo por Vezzani et al. (2004) [51] y Hopp and Foley (2001) [59], la fiebre de dengue presenta importantes patrones estacionales y la transmisión intensa coincide con los meses más húmedos y de abundantes precipitaciones del año. La variable precipitación es un factor limitante de la actividad del vector (Estallo et al., 2012 [56]). La cobertura vegetal (NDVI) tiene una fuerte asociación con la temperatura, la precipitación y las propiedades del suelo. Esta variable cobra relevancia porque provee en general refugio y alimento a los animales. Kiang et al. (2012) [55], Peterson et al. (2005) [60]; Tourre et al. (2008) [61] y Estallo et al. (2008) [6] incorporaron a sus modelos predictivos la variable NDVI. La altitud, la pendiente y exposición suelen ser también factores determinantes en la distribución del vector (Peterson et al. (2005) [60]). La variable altitud (DEM) está asociada a la variable temperatura (LST), y en general *Ae. aegypti* se encuentra por debajo de los 2000 msnm (Navarro et al., 1998 [62]; Lanfri et al., 2013 [63]; Carbajo et al., 2001 [64]).

4.2. Metodología

La metodología consiste en el desarrollo de un modelado de Favorabilidad Ambiental para *Ae. aegypti* a nivel provincial, usando un modelo de Máxima Entropía (MaxEnt).

4.2.1. Favorabilidad Ambiental para *Ae. aegypti* a nivel provincial, mediante un modelado de Máxima Entropía

En la identificación de las zonas adecuadas para el desarrollo del vector se consideraron variables ambientales que, por bibliografía se sabe que inciden en las condiciones generales de su hábitat. Estas variables fueron estimadas a través de datos generados desde información satelital (imágenes satelitales). En este apartado se contó con los siguientes datos:

- Datos de localización de la especie
Se obtuvieron 16 sitios, georreferenciados (dentro de la provincia de Jujuy) con presencia del vector, datos aportados por el Departamento Provincial de Control de Vectores (Ministerio de Salud de la provincia de Jujuy).
- Datos ambientales
Se usaron las siguientes variables biogeofísicas remuestreadas a una resolución espacial de 250 metros:

A Modelo Digital de Elevación (DEM)

Para la obtención de los DEM se ingresó a la siguiente página (<http://www.viewfinderpanoramas.org/dem3.html#andes>), desde allí se seleccionó "South America". Los DEM obtenidos pertenecen a la Base de Datos del SRTM (Shuttle Radar Topography Mission) con una resolución espacial de 90 m. y luego fueron remuestreados a 250m. Usando las herramientas de Envi 4.7 se obtuvieron a partir de los mismos las características del "aspecto" y la "pendiente", variables empleadas también por Kumar and Stohlgren (2009) [65]. En la figura 4.1 se muestra la secuencia de pasos para obtener un DEM de la provincia de Jujuy, a partir de los *tiles* descargados de la página http://www.viewfinderpanoramas.org/Coverage%20ma%20viewfinderpanoramas_org3.htm.

Se utilizó un shapefile de la provincia de Jujuy para hacer el recorte de todas las variables empleadas en el modelo.

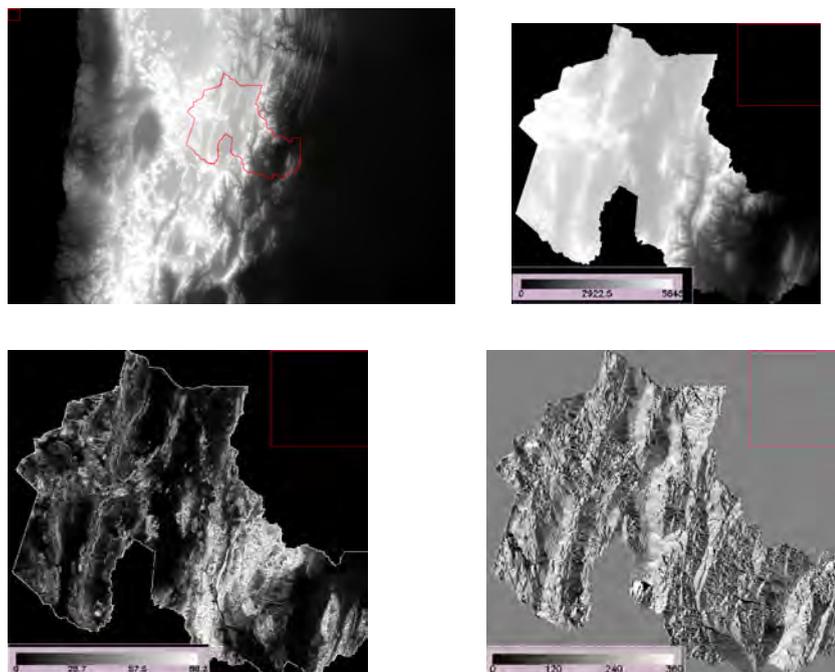


FIGURA 4.1: a) Mosaico realizado a partir de los tiles del SRTM de 90m (sup. izq.) b) Imágen DEM de la provincia de Jujuy (sup. der.) c) Imágen “slope” para la provincia de Jujuy (inf. izq.) d) Imágen “aspect” para la provincia de Jujuy (inf. der.)

B Precipitación

Se adquirieron datos de precipitación mensual acumulada y media mensual, a nivel continental de la base de datos del TRMM (Tropical Rainfall Measuring Mission) de la NASA, desde la siguiente página web: (http://gdata1.sci.gsfc.nasa.gov/daacbin/G3/gui.cgi?instance_id=TRMM_Monthly). Se evaluó el ciclo de precipitaciones anual, observándose un patrón temporal que denota la presencia de una estación seca, que va en general de junio a noviembre y otra estación húmeda que va de diciembre a mayo (Lamfri et al, 2013) [63], como se puede observar en la figura 4.2.

Se seleccionó una serie temporal comprendida entre el año anterior al brote y mediados del año del brote (enero de 2008 a julio de 2009).

Cabe señalar que se realizó para todas las series temporales un Análisis de Componentes Principales seleccionándose las primeras dos componentes para los modelos, porque entre ambas describen más del 80 % de la variabilidad del conjunto de datos .

En la figura 4.3 se observa una imagen obtenida desde la página del TRMM, con el recorte realizado para la provincia.

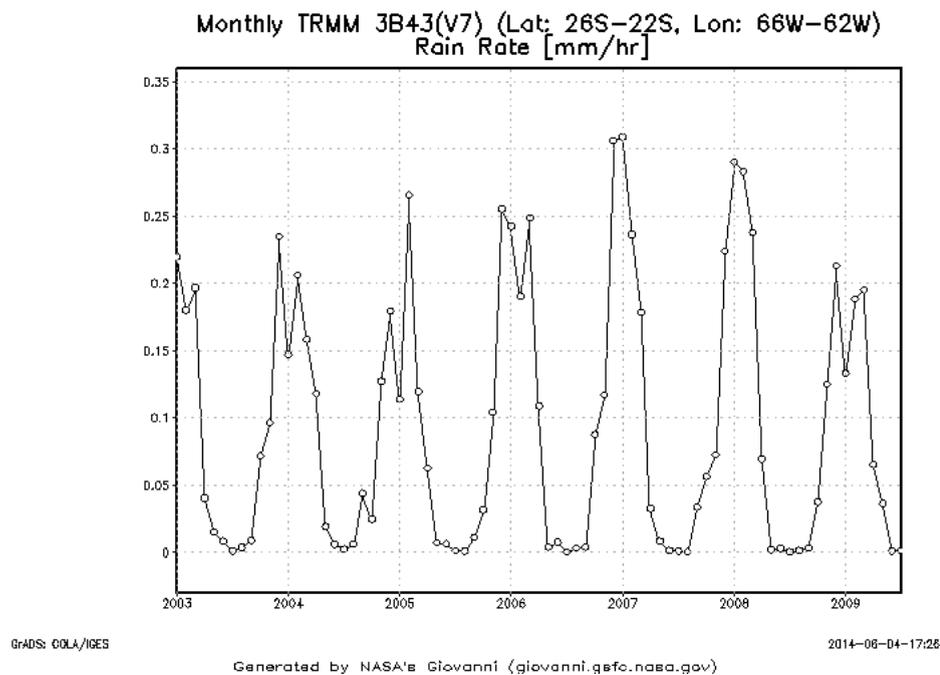


FIGURA 4.2: Ciclo anual de precipitaciones medias mensuales, entre los años 2003 y 2009. Obtenido desde giovanni.gsfc.nasa.gov

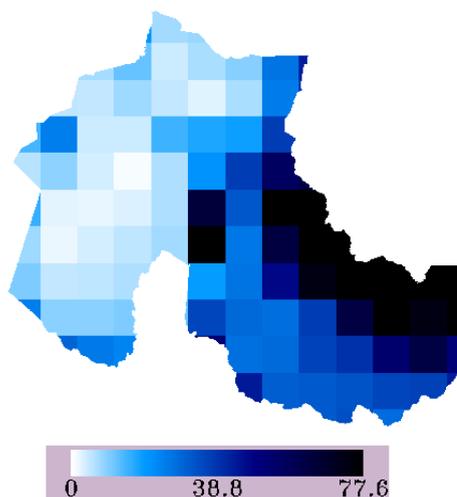


FIGURA 4.3: Precipitación acumulada mensual

C Cobertura de Suelos

Para la obtención de un mapa de la provincia de Jujuy, con las distintas coberturas de suelo se recurrió al producto “*land cover product*”, del proyecto GlobCover 2009. Este proyecto consta de un mapa de 22 tipos de coberturas a nivel global (con una resolución espacial de 300m), realizado a partir de una clasificación automatizada de una serie temporal de MERIS FR. La figura 4.4, muestra un mapa de la provincia de Jujuy con las diferentes coberturas obtenidas a partir del proyecto Globe

Cover y una grilla con las referencias de las coberturas. El mapa es el resultado de una composición en RGB (por sus siglas en inglés de los canales: Red, Green, Blue), por tanto el cursor ubicado sobre cada clase revela el valor para cada canal. Las clases resaltadas con color amarillo sobre la grilla corresponden a aquellas que coinciden con los puntos de las localidades con presencia del vector.

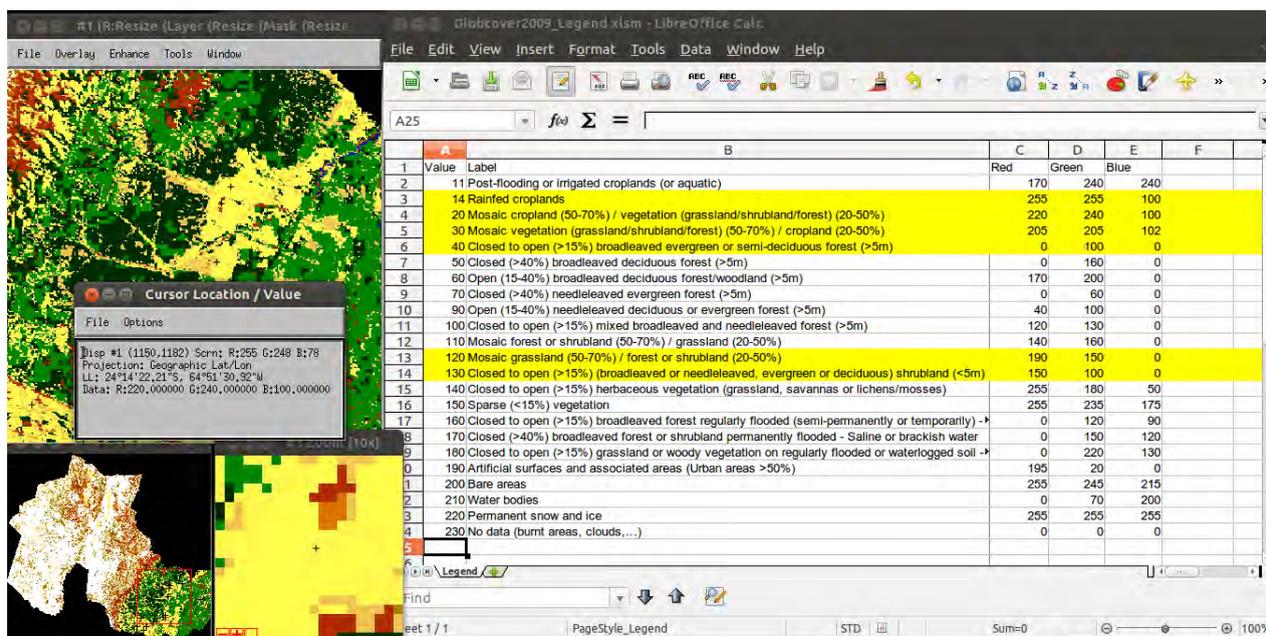


FIGURA 4.4: Mapa de coberturas de la provincia de Jujuy. Obtenido desde GlobeCover 2009.

D Índice de Vegetación Normalizado (NDVI)

El NDVI se obtuvo a partir de una serie temporal desde enero de 2008 hasta julio de 2009. Este producto de MODIS, cuenta con una resolución espacial de 250m y una resolución temporal de 16 días.

La figura 4.5 muestra el mapa de Índices de Vegetación Normalizados para la provincia de Jujuy.

E Temperatura Superficial de la Tierra (LST)

La LST, se obtuvo a partir de una serie temporal desde enero de 2008 hasta julio de 2009. Este producto de MODIS, cuenta con una resolución espacial de 1 km y el valor del píxel es el mayor contenido en un período de ocho días. La figura 4.6 muestra el mapa de la provincia de Jujuy con los valores de LST,

- Análisis de Componentes Principales (ACP)

Al calcular la covarianza entre los valores de reflectancia de las distintas bandas

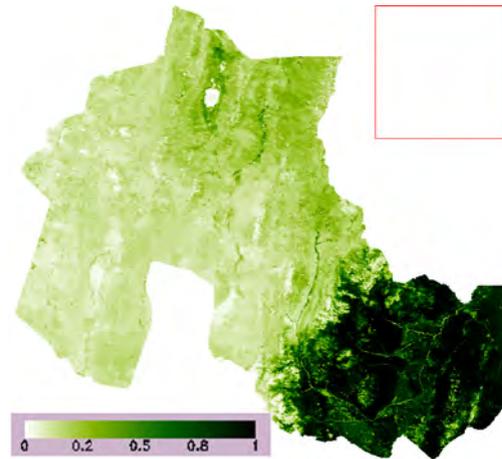


FIGURA 4.5: Mapa de Índice de Vegetación Normalizado. Obtenido desde productos MODIS.

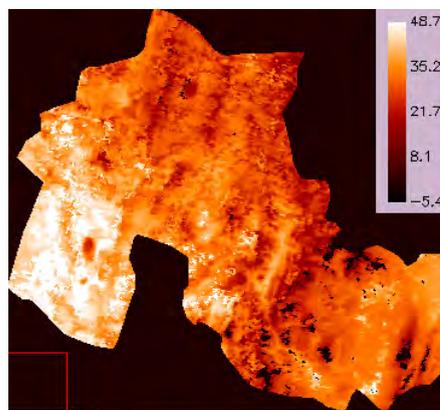


FIGURA 4.6: Mapa de Temperatura Superficial de la Tierra, en grados Centígrados. Obtenido desde productos MODIS.

espectrales de las imágenes multiespectrales, se observa una cierta redundancia. Para resolver este problema surge el ACP, se trata de una técnica estadística de síntesis de la información, o reducción de la dimensión (es decir, el número de variables) y sumarla la redundancia sin una pérdida sustancial de información (Niell and Carreira, 1995) [66]. El ACP construye una transformación lineal que escoge un nuevo sistema de coordenadas para el conjunto original de datos en el cual la varianza de mayor tamaño del conjunto de datos es capturada en el primer eje (la Primera Componente Principal), la segunda varianza más grande es el segundo eje, y así sucesivamente. Un ACP tiene sentido si existen altas correlaciones entre las variables, esto es lo que produce la redundancia en la información, por tanto, pocos factores explicarán gran parte de la variabilidad total. Es por eso que resulta muy útil aplicar esta técnica en las series temporales.

4.2.2. Modelado Ecológico para *Ae. aegypti*

En este trabajo los modelos predictivos de presencia del vector en la provincia de Jujuy se han construido con el software MaxEnt 3.3.3, acrónimo de “máxima entropía”, un algoritmo que ha sido adaptado para la construcción de modelos de distribución geográfica potencial de las especies, por Steven J. Phillips y colaboradores. El método está descrito en varias publicaciones que se incluyen en la bibliografía (Phillips et al., 2004 [67]; 2006 [68]). Varios trabajos muestran que este algoritmo determina de una mejor forma las áreas de distribución potencial adecuadas vs. no adecuadas y cuyo valor predictivo es más confiable, en comparación con otros, como GARP, DOMAINE, BIOCLIM, entre otros (Elith et al. 2011 [69]; Hernández et al. 2006 [70], Phillips 2008 [71]; Phillips et al, 2004 [67], 2006 [68]; Ramos, 2011 [72]). El enfoque consiste en encontrar la distribución de probabilidad de entropía máxima, que es la más cercana a la distribución uniforme, condicionada por las restricciones impuestas por la información disponible sobre la distribución observada de la especie y las condiciones ambientales del área de estudio. Los fundamentos de MAXENT son los siguientes:

- ✓ La distribución de una especie se representa mediante una función de probabilidad P sobre un conjunto X de lugares en el área estudiada. P asigna un valor positivo a todo lugar x de forma que la suma de $P(x)$ es la unidad.
- ✓ Se construye un modelo de P mediante un conjunto de restricciones derivadas de datos empíricos de presencia.
- ✓ Las restricciones se expresan como funciones simples de variables ambientales conocidas, $f(v)$.
- ✓ El método que usa MaxEnt obliga a que la media de cada función de cada variable esté próxima a la media real de la variable en las zonas de presencia; por ejemplo, la función correspondiente a la precipitación de enero debe generar una predicción de la misma cercana a la precipitación real observada.
- ✓ De las posibles combinaciones de funciones, se utiliza la que minimiza la función de entropía medida con el índice de Shannon lo que, según los autores, permite realizar una selección óptima de variables y funciones en función de su significación y eliminar las que no aportan restricciones significativas al modelo.

La forma general de la función de probabilidad es, para i variables ambientales:

$$P(X) = \frac{e^{\lambda f(x)}}{Z_\lambda} \quad (4.1)$$

Donde λ representa un vector de coeficientes de ponderación y \mathbf{f} el vector correspondiente de funciones.

Z es una constante de normalización que se utiliza para asegurar que $P(x)$ es la unidad. Los autores señalan que los valores $P(x)$ deben interpretarse como valores de idoneidad relativa. Estos valores son normalmente transformados mediante una función logística que se ajusta a una escala en el rango entre 0 (incompatible) y 1 (idóneo). Los valores son calculados para cada punto de la zona de estudio y "mapeados" de forma que se obtiene una representación cartográfica utilizable directamente en un sistema de información geográfica: el modelo de distribución potencial. Como este mapa presenta valores continuos entre 0 y 1 será útil para estadísticas y comparaciones estimar un valor de corte óptimo para separar dos clases únicas que muestran las estimaciones para zonas de presencia y de ausencia. Además dentro de los resultados se incluye información sobre las dependencias entre variables y presencias, que permiten analizar las posibles relaciones funcionales que el modelo puede potencialmente revelar.

4.2.2.1. Evaluación de las predicciones

Es necesario realizar una evaluación de qué tan fidedignas son las predicciones hechas por el modelo. Se utilizó el área bajo la curva AUC (por sus siglas en inglés: Area Under the Curve) de los ROC-plot (Receiver Operating Characteristic) que es un método gráfico para evaluación, organización y selección de sistemas de diagnóstico y/o predicción. Además es una medida independiente de la prevalencia y correlacionada con el Kappa (Anderson et al., 2003 [73]). Mientras más próximo a 1 (uno) sea la AUC, mejor el desempeño del modelo. Este estadístico nos permite evaluar los casos clasificados correctamente para todos los umbrales de predicción (del 0 al 1). El valor de AUC varía entre 0,5 y 1; donde un valor de 0,5 equivale a una clasificación al azar; mientras que un valor de 1 indica un ajuste perfecto; es decir, que todos los casos han sido clasificados correctamente (Fielding y Bell, 1997 [74]).

4.2.2.2. Preparación de los datos de entrada

Para la generación de modelos en MaxEnt fue necesario administrarle dos tipos de archivos. Por un lado un archivo que contenga la ubicación geográfica (coordenadas) de las localidades, en dónde se registraron los casos humanos de dengue, y por otro lado

un directorio que contenga las capas de variables ambientales (biofísicas), en formato raster.

1. Archivos de Datos de Presencia, en formato “.csv”

Los datos de presencia se ordenaron en tres columnas, desde un archivo Excel: Casos, Longitud, Latitud (Coord. Geográficas).

2. Capas de Variables Ambientales

Las capas en formato raster, deben tener el mismo tamaño de píxel, extensión y proyección, teniendo presente que éstas deben coincidir con las coordenadas de los Datos de Presencia. En este caso se emplearon coordenadas geográficas WGS-84 (Lat-Lon). Las variables predictoras fueron procesadas (con el mismo tamaño de píxel por lo que se realizó previamente un layerstack con todas las bandas) usando el software Envi 4.7. Cabe destacar que el MaxEnt toma las variables en formato ASCII (.asc), por lo que los rasters obtenidos desde Envi, fueron guardados con la extensión “.dat”, para luego importarlos desde el software ESRI ArcGIS© 9.3 y convertirlos en formato ASCII.

4.2.2.3. Configuración del programa

Se configuró el test aleatorio de porcentaje (Random test percentage) al 25 % (Porcasi et al. 2012 [3]). De esta manera, MaxEnt divide el conjunto de datos de presencia en dos porciones: una con los datos de entrenamiento (localidades de presencia) y la otra con los datos de prueba (25 % de los datos de entrenamiento) y utiliza estos últimos para efectuar la prueba de efectividad (Phillips et al. 2006 [68]). MaxEnt genera dos tipos de formatos de salida: acumulativo y logístico. A partir del formato de salida acumulativo se obtiene un mapa con una dicotomía simple entre *ambiente apto* para la presencia de la especie vs. *ambiente no apto*, en base a las variables utilizadas para generar el modelo. Este tipo de formato de salida es menos sensible al sesgo producido por el esfuerzo de muestreo diferencial entre las áreas y como resultado dará un mapa que será interpretado como la predicción de las condiciones adecuadas para la presencia de la especie. A través de la configuración de un valor umbral acumulativo, MaxEnt predecirá una tasa de omisión por debajo de la cual el ambiente no será apto para la presencia de la especie. Mientras que el otro formato de salida, el logístico debe ser interpretado como la probabilidad de hallar a la especie dentro del ambiente identificado como apto (su valor varía entre 0-1) (Phillips et al. 2006 [68]). Dicha probabilidad, dependerá de la dificultad en obtener datos de la presencia de la especie (es decir de su densidad poblacional) y por lo tanto del esfuerzo de muestreo. La salida logística estima la probabilidad de presencia asumiendo que el diseño de muestreo es tal que las localidades de presencia típicas tienen una probabilidad

de presencia de alrededor de 0,5 (Ellith et al. 2011 [69]). De esta forma la salida logística debe ser interpretada como el 50 % de probabilidades que la especie este presente en un ambiente apto (Elith et al. 2011 [69]). Para la configuración del MaxEnt se introdujo 1000 como número máximo de interacciones, estableciendo el límite de convergencia en 0.00001 y el valor de regulación en 0.0001. Según Phillips et al. (2006) [68] estos valores son adecuados y garantizan la convergencia del algoritmo.

4.3. Resultados

4.3.1. Tasa de Omisión

En general es conveniente trabajar con umbrales a fin de tener una predicción binaria, suponiendo condiciones adecuadas por encima del umbral e inadecuadas por debajo del mismo. La siguiente figura 4.7 muestra como varían las tasas de omisión para la muestra de entrenamiento y el área predicha como favorable en función del umbral elegido. La tasa de omisión es el porcentaje de valores verdaderos no detectados y lógicamente aumenta según sube el valor umbral que separa lo inadecuado de lo idóneo. Para un umbral muy bajo, todos los positivos son clasificados como tales aunque se generan tasas muy elevadas de error de comisión, es decir negativos clasificados como positivos o falsos positivos. A continuación se detalla el significado de cada una de las líneas en color que muestran estas relaciones:

- *línea roja*: superficie clasificada como adecuada en función del umbral.
- *línea celeste*: omisión de los datos de evaluación: positivos no clasificados como tales (error de omisión).
- *línea negra*: omisión prevista.

La tasa de omisión debe ser próxima a la omisión prevista, a causa del umbral acumulativo, de modo que el resultado del modelo predictivo obtenido para *Ae. aegypti* a través del modelado MaxEnt puede ser considerado **adecuado**.

4.3.2. Curva ROC y AUC

El siguiente gráfico es el de la **Sensibilidad vs. Especificidad**. La sensibilidad indica la capacidad del estimador para clasificar como casos positivos aquellos que son realmente

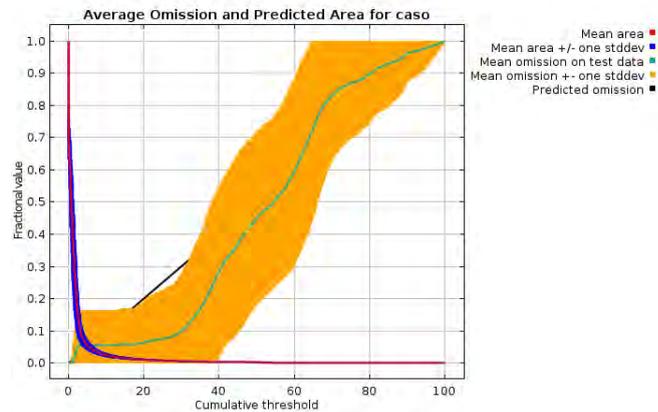


FIGURA 4.7: Gráfico Tasas de omisión

positivos, es entonces la proporción de positivos correctamente identificados. La especificidad indica la capacidad del estimador para clasificar como casos negativos aquellos que son realmente negativos, es entonces la proporción de negativos correctamente identificados. La curva ROC (por sus siglas en inglés *Area Under the Receiver Operating Characteristic*) (fig.4.8) muestra las relaciones entre falsos positivos y falsos negativos para los diferentes umbrales y el área bajo la curva (AUC) es un estadístico de ajuste. Un modelo que prediga más acertadamente la distribución de una especie generará una curva ROC que siga el eje izquierdo hasta lo alto del gráfico (línea roja), mientras que un modelo que prediga “no mejor que al azar” generará una curva ROC que siga la línea 1:1 (diagonal).

Un valor de AUC menor o igual a 0,5 indica que el desempeño del modelo no es mejor que el azar, mientras que un valor cercano a 1 indica un mejor rendimiento del modelo. El valor del AUC para *Ae. aegypti* fue de 0.994.

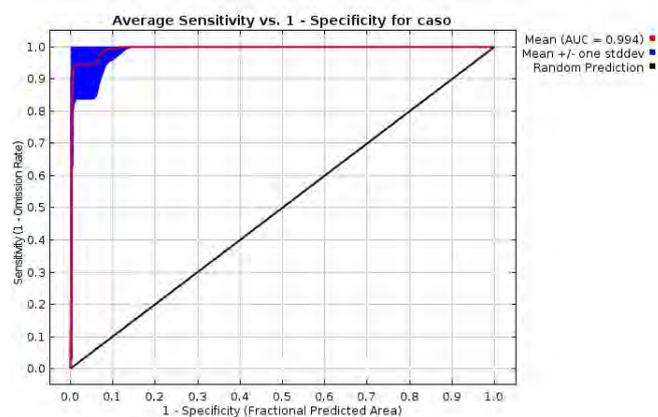


FIGURA 4.8: Gráfico de la Curva ROC (AUC)

4.3.3. Curvas de Respuestas

Estas curvas muestran la influencia de cada variable ambiental sobre la predicción de Maxent y como la predicción logística cambia con cada variable ambiental, mientras se mantienen todas las otras variables ambientales en su valor medio antes señalado. Las curvas pueden ser difíciles de interpretar si se tienen variables fuertemente correlacionadas, y el modelo puede depender de la correlación de formas que no son evidentes en las curvas. En otras palabras, las curvas muestran el efecto marginal del cambio de una variable, mientras el modelo puede restar validez a los conjuntos de variables que cambian juntas. Las curvas muestran la respuesta media para unas 1000 iteraciones.

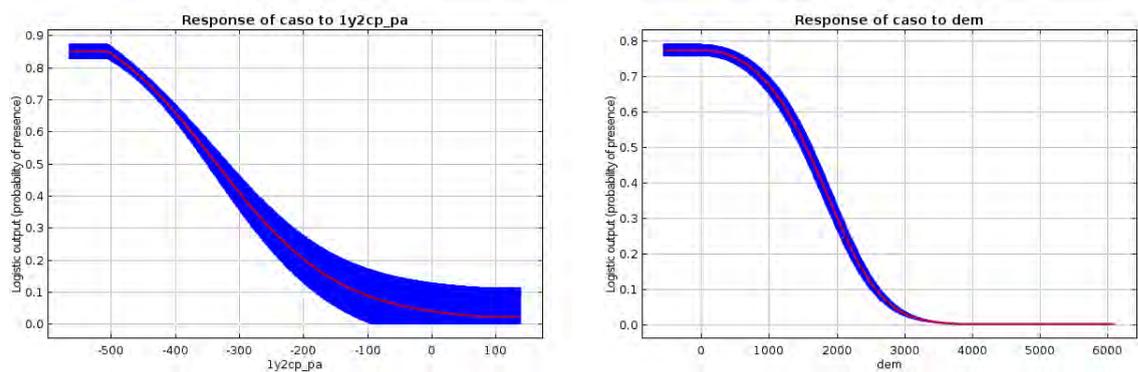


FIGURA 4.9: a) (izquierda) Curva de respuesta de la variable *Precipitación Acumulada*, b) (derecha) Curva de respuesta de la variable *DEM*.

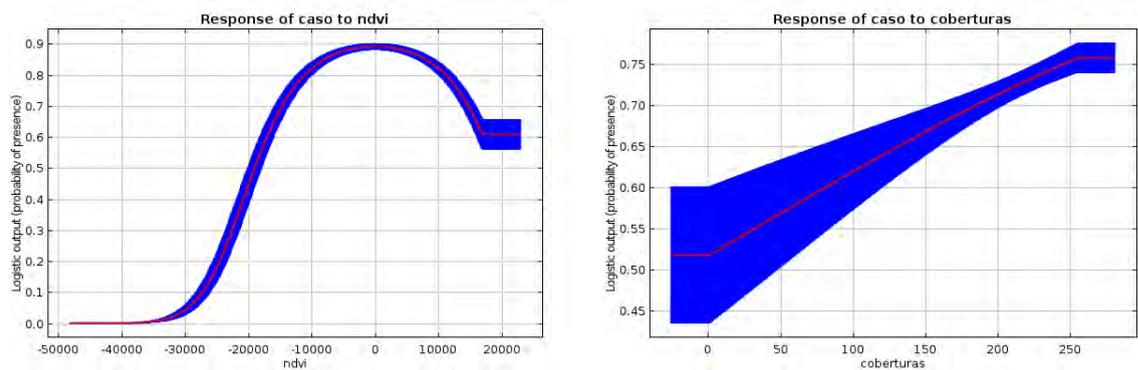


FIGURA 4.10: a) (izquierda) Curva de respuesta de la variable *NDVI*, b) (derecha) Curva de respuesta de la variable *Coberturas*.

La variable “Precipitación Acumulada” (fig.4.9a) tiene incidencia en el modelo cuanto más bajos son los valores que asume, esto es así porque dentro de la imagen de precipitación acumulada los píxeles mas oscuros tienen valores bajos y representa mayor acumulación de precipitaciones. En el caso de la variable “DEM” (fig.4.9b) su incidencia disminuye a medida que aumenta el valor de la variable, esto quiere decir los lugares con mayor probabilidad o más aptos para el desarrollo del insecto son los valles. Cabe

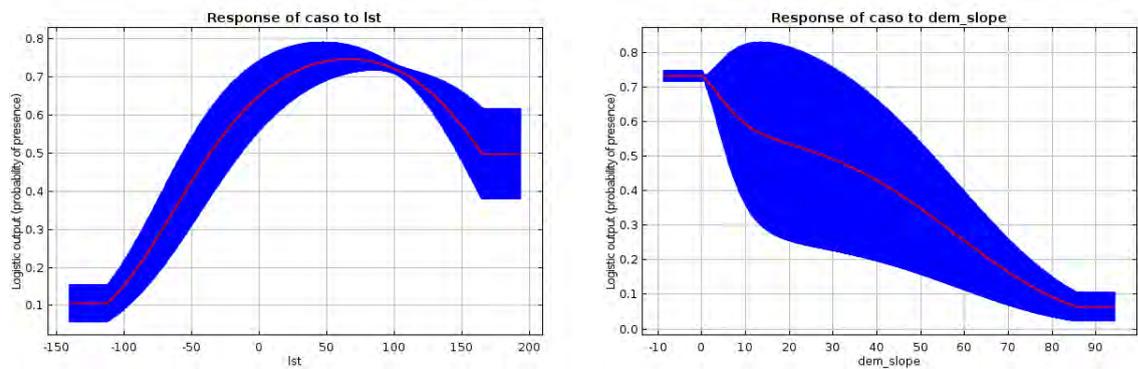


FIGURA 4.11: a) (izquierda) Curva de respuesta de la variable *LST*, b) (derecha) Curva de respuesta de la variable *DEM_Slope*.

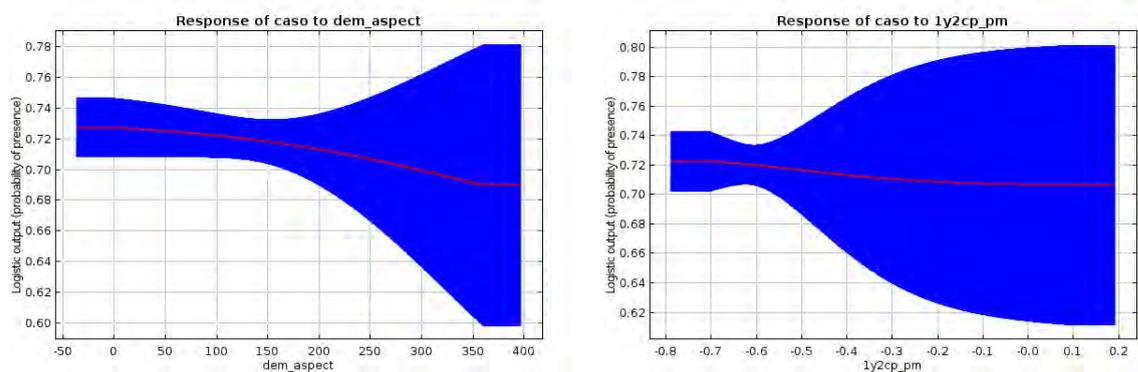


FIGURA 4.12: a) (izquierda) Curva de respuesta de la variable *DEM_Aspect*, b) (derecha) Curva de respuesta de la variable *Precipitación Media*.

señalar que desde el DEM utilizado se obtuvieron a su vez dos características: la “pendiente” (fig.4.11b) y la “exposición” (fig.4.12a). Se puede observar que a medida que aumenta la pendiente del terreno, disminuye su incidencia en el modelo. Mientras que independientemente de los valores que asume la variable exposición, la incidencia sobre el modelo parecería permanecer constante. La variable “LST” (fig.4.11a) incide a medida que va aumentando su valor, hasta llegar a un máximo a partir del cual su incidencia comienza a decrecer. De manera similar se observa en la variable “NDVI” (fig.4.10a). La variable “Coberturas” (fig.4.10b) contribuye al modelo cuanto más altos son los valores. Dicha variable representa una clasificación de los valores de reflexión de una imagen Landsat 5 TM, aquellos mas altos son obtenidos desde las ciudades. Es importante tener en cuenta que los valores que aparecen en los gráficos para las variables a las que se les aplicó un Análisis de Componentes Principales, responden a una nueva dimensión.

4.3.4. Contribución de las variables

A continuación se muestra una tabla 4.1 con el porcentaje de contribución relativa de las variables ambientales en el modelo generado. La variable ambiental que más incide en el modelo es Precipitación Acumulada, con un porcentaje del 39.1%, otras variables ambientales con porcentajes representativos son DEM con un 25% y NDVI con un 23.7%.

CUADRO 4.1: Contribución de las Variables (Modelo MaxEnt)

Variable	Abreviatura	contribución (%)
Precipitación Acumulada	1y2cp_pa	39.1
Modelo de Elevación del terreno	DEM	25
Índice Normalizado de Vegetación	NDVI	23.7
Coberturas del terreno	coberturas	7.5
Temperatura Superficial del Terreno	LST	3.7
Pendiente del terreno	DEM_Slope	0.6
Exposición del terreno	DEM_Aspect	0.2
Precipitación Media	1y2cp_pa	0.1

4.3.5. Test de Jackknife

El test de JACKKNIFE es una herramienta presente en el algoritmo MaxEnt que permite estimar la significancia de forma individual de cada variable ambiental en el modelo generado (Anderson et al 2003 [73]). En el siguiente gráfico 4.13 es posible identificar qué variable contribuye mucho más de forma individual.



FIGURA 4.13: Test de Jackknife

La variable ambiental que más contribuye en el modelo, cuando éste toma sólo esa variable para correr es el NDVI. Es decir que esta es la variable con mayor ganancia, la que tiene mayor información útil para el modelo. De hecho cuando el modelo corre sin esta variable, la ganancia del mismo disminuye significativamente. Luego le siguen en orden decreciente la precipitación (media y acumulada), el DEM, LST, Coberturas, Pendiente y finalmente la Exposición.

4.3.6. Mapa predictivo

La siguiente imagen 4.14 muestra el mapa de predicción, generado a partir de los datos de presencia de *Ae. aegypti* en las localidades de la provincia de Jujuy.

Debido a que el modelo sobrestimó en algunas áreas, entonces se empleó una capa shape de los Ejidos Urbanos. Además fue necesario aplicar un filtro lineal, para mejorar la apariencia.

4.3.7. Favorabilidad ambiental por localidad

Desde ArcGIS 9.3, se empleó una herramienta **Selección de puntos a partir de un raster** para resaltar aquellas localidades que presentan mayor favorabilidad ambiental

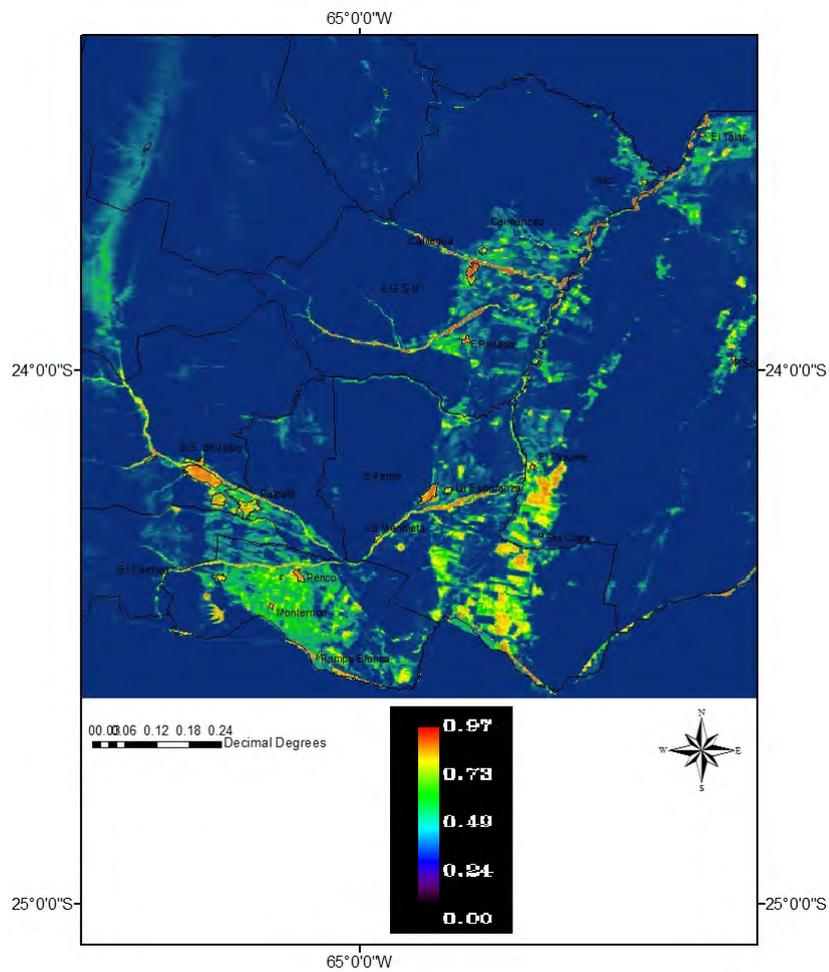


FIGURA 4.14: Mapa de favorabilidad ambiental, para el desarrollo del vector. Provincia de Jujuy

para el desarrollo del vector, a partir de registros de presencia del vector en determinadas localidades de la provincia y de esta manera se obtuvo el mapa que se muestra en la figura 4.15.

Esta herramienta además, arrojó las siguientes tablas (fig. 4.17), (fig. 4.16), (fig.4.18), (fig.4.19) dónde se muestran los valores de probabilidad que presenta cada localidad, para el desarrollo del vector, en base a variables ambientales. Las tablas están clasificadas según sus cuatro eco-regiones: Puna, Quebrada, Valle y Yungas.

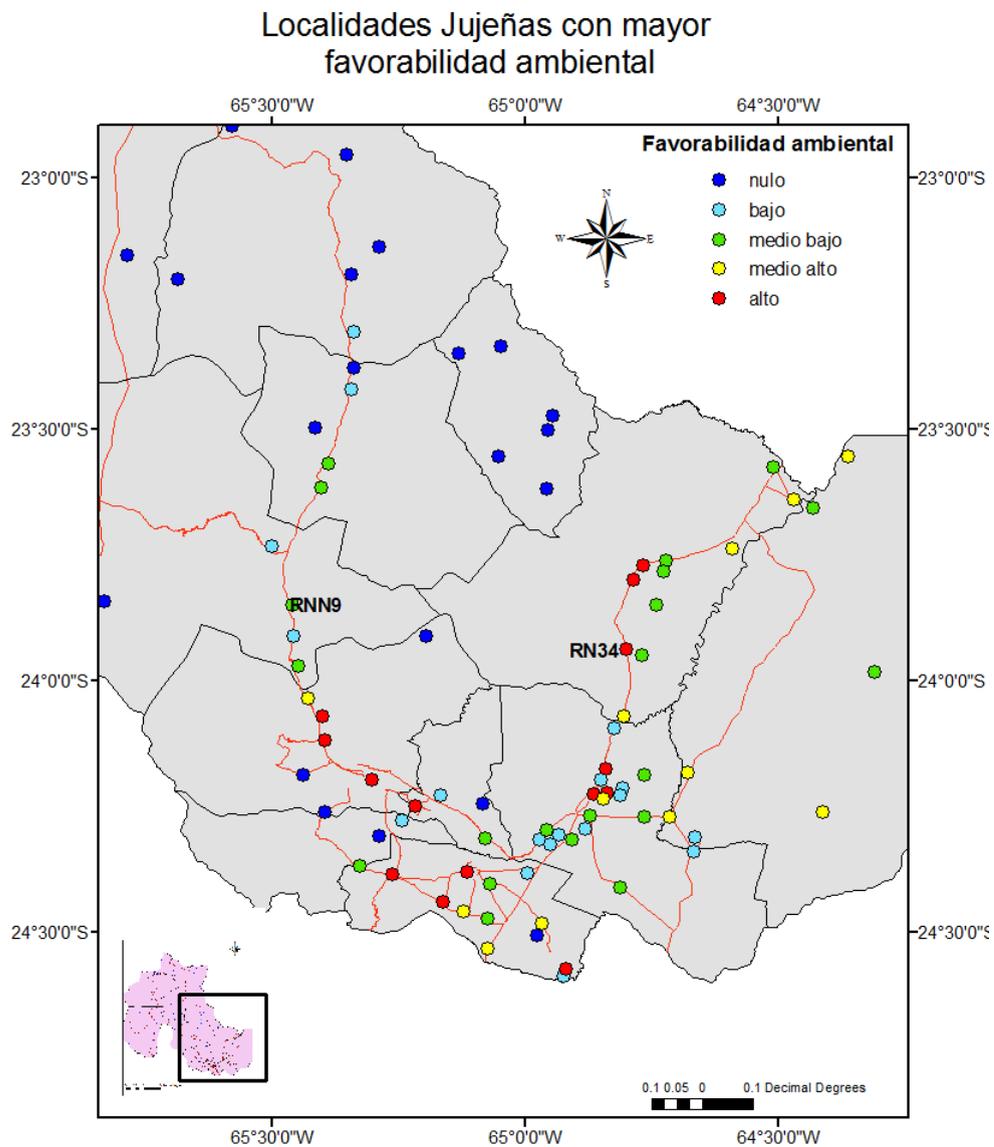


FIGURA 4.15: Localidades de la provincia de Jujuy con favorabilidad ambiental, con una rampa de color señalando con rojo la probabilidad mas alta y con azul, la probabilidad nula.

4.4. Discusión

Como sostienen Focks et al., (1993) [46]) las condiciones macroambientales condicionan la distribución de *Ae. aegypti*. En los mapas predictivos generados por el MaxEnt, se observa un patrón de distribución del vector en la provincia de Jujuy, que responde a las diversas variables ambientales y climáticas. Los sitios con mayor probabilidad presentan rangos de valores de las variables, que son óptimos para que el vector se desarrolle.

COCHABAMBA	HUMAHUACA	HUMAHUACA	LIQUIA	3,24%
			HUMAHUACA	1,17%
			COCTACA	0,94%
			HIPOLITO YRIGROYEN	0,35%
			TRES CRUCES	0,15%
	EL AGUILAR	0,11%		
	TILCARA	TILCARA	TILCARA	12,93%
			MAIMARA	10,40%
			HUACALERA	5,11%
			COLONIA SAN JOSE	3,03%
IJELLA			0,48%	
TUMBAYA	TUMBAYA	TUMBAYA	16,70%	
		BARCENA	13,83%	
		VOLCAN	4,66%	
		PUJNAMARCA	4,16%	
		EL MORENO	0,69%	

FIGURA 4.16: Localidades de la Eco-región de la Quebrada, con favorabilidad ambiental

En general el Modelo de Máxima Entropía, toma variables ambientales provenientes del worldclim, pero en este trabajo se emplearon variables ambientales y climáticas provenientes de distintas fuentes, tales como productos de precipitación desde el *Tropical Rainfall Measuring Mission (TRMM)*, productos del catálogo de la página de *Moderate Resolution Imaging Spectroradiometer (MODIS)*, DEM desde la página del *Shuttle Radar Topography Mission (SRTM)*, y los productos de coberturas del suelo, generados por el proyecto Glovis Globe Cover 2009. Con respecto a la Tasa de Omisión, se observa que la línea celeste, que representa los positivos no clasificados como tales, se aproxima o ajusta bastante a la línea negra, que representa la omisión prevista. En general la tasa de omisión prevista es una línea recta por definición del formato acumulativo de salida. En este caso la línea de la omisión de los datos de evaluación se encuentra por debajo de la línea de omisión prevista y una razón común es que los datos tanto de entrenamiento como de evaluación no son independientes, ya que derivan de datos de presencia correlacionados espacialmente (Phillips, 2005) [75]. La curva ROC sigue el eje izquierdo hasta lo alto del gráfico, distinguiéndose de la línea 1:1 (diagonal), descrita por los modelos que no predicen mejor que el azar. El valor de la curva AUC de la prueba externa (prueba independiente) realizado en MaxEnt para *Ae. aegypti* de 0.994, esto implica un muy buen desempeño del modelo generado (Phillips, 2005) [75].

Uno de los factores importantes para el desarrollo de los estados inmaduros del vector es el agua. En 2012, Zambrano et al. [54] encontraron que la variable precipitación acumulada tenía un buen desempeño como predictora, ya que antecedió los brotes de dengue en Honduras, por su parte Kiang et al. (2012) [55] encontraron también esta relación en Indonesia (junto con otras variables como la temperatura y la humedad).

	Departamento	Cabecera	Localidad	PROBABILIDAD		
PUNA	SUSQUES	SUSQUES	PASTOS CHICOS	0,06%		
			PUERTO SEY	0,05%		
			SAN JUAN DE QUILLAQUES	0,04%		
			HUANCAR	0,04%		
			MINA PROVIDENCIA	0,02%		
			OLARCOZ CHICO	0,02%		
			EL TORO	0,01%		
			CORANZULI	0,01%		
			LATUA	0,00%		
			SUSQUES	0,00%		
			RINCONADA	RINCONADA	RINCONADA	0,08%
	LIVARA	0,02%				
	NUEVOPIRQUITAS	0,00%				
	LAGUNILLAS DE FARALLON	0,00%				
	SANTA CATALINA	SANTA CATALINA	SANTA CATALINA	5,25%		
			LA CIENEGA	0,34%		
			SAN JUAN DE OROS	0,14%		
			CIENEGA	0,14%		
			PAICONE	0,12%		
			CASIRA	0,11%		
			YOSCABA	0,10%		
			ORATORIO	0,10%		
			CIENEGUILLAS	0,07%		
			MISARRUM	0,06%		
			CUSI CUSI	0,01%		
			YAVI	LA QUIACA	YAVI	0,32%
					LA INTERMEDIA	0,25%
	CANGREJILLOS	0,17%				
	PUMAHUASI	0,16%				
	BARRIOS	0,13%				
	YAVI CHICO	0,11%				
	EL CONDOR	0,05%				
	LULLUCHAYOC	0,03%				
	LA QUIACA	0,01%				
	COCHINCOA	ABRA PAMPA			RINCONADILLAS	4,07%
			SAN FRANCISCO DE ALFARCO	4,01%		
			TUSAQUILLAS	1,30%		
			ABRACAITE	0,72%		
			SANTOVARO DE TRES POZOS	0,63%		
			ABRA PAMPA	0,32%		
			COCHINCOA	0,13%		
			CASABINDO	0,12%		
ABDON CASTRO TOLAY			0,08%			
PUERTO DEL MARQUEZ			0,08%			

FIGURA 4.17: Localidades de la Eco-región de la Puna, con favorabilidad ambiental

Estallo et al. (2011) [16] encontraron una asociación directa entre las precipitaciones ocurridas y registradas en la ciudad de Orán (provincia de Salta) y la abundancia de huevos de *Ae. aegypti*. En el modelado de MaxEnt de este trabajo, la variable que más contribuye al modelo es la *Precipitación Acumulada*, esto puede interpretarse en relación a los recipientes dónde se acumula agua y que favorecen los sitios de cría necesarios para el desarrollo de los estadios inmaduros de pupa y larva de *Ae. aegypti*, como sostienen Patz et al., (2006) [57] existe una relación directa entre la cantidad de recipientes que acumulen

VALLES	DR. MANUEL BELGRANO	SAN SALVADOR DE JUJUY	SAN SALVADOR DE JUJUY	83,48%
			LOZANO	80,79%
			YALA	71,68%
			LEON	51,58%
			LA ALMONA	2,95%
			GUERRERO	1,99%
			OCLOYÁS	0,33%
	PALPALA	PALPALA	PALPALA	71,93%
			CARAHUNCO	11,47%
			CENTRO FORESTAL	6,78%
			MINA 9 DE OCTUBRE	0,65%
	SAN ANTONIO	SAN ANTONIO	SAN ANTONIO	13,62%
			LOTEO NAVEA	8,73%
			EL CEIBAL	1,55%
	EL CARMEN	EL CARMEN	PERICO	81,03%
			MONTE RICO	79,40%
			EL CARMEN	70,15%
			SAN ISIDRO	65,83%
			PAMPA BLANCA	53,76%
			BARRIO EL MILAGRO	42,61%
			PUESTO VIEJO	39,24%
			LOS LAPACHOS	25,65%
			BARRIO LA UNION	10,82%
			SAN JUANCITO	4,73%
			AGUAS CALIENTES	4,09%
			MANANTIALES	3,05%

FIGURA 4.18: Localidades de la Eco-región del Valle, con favorabilidad ambiental

agua de lluvia y la presencia y densidad del vector. Esta situación lleva consecuentemente a incrementar la potencial transmisión de dengue (Hales et al., 2003) [58]. De hecho las investigaciones realizadas por Vezzani et al. (2004) [51] y Hopp and Foley (2001) [59] demostraron que las transmisiones mas altas de dengue se asocian a los meses de mayor precipitación y humedad.

La provincia de Jujuy presenta longitudinalmente un gradiente altitudinal decreciente de Oeste a Este y los registros de presencia del vector se encuentran en el sureste de la provincia, específicamente en las zonas de los Valles, donde la altitud en general no supera los 2000 msnm. En el cuadro de Contribución de las variables, generado por MaxEnt, la segunda variable predictor que mejor contribuye al modelo es el DEM y cuanto más bajos son los valores de esta variable, mayor favorabilidad ambiental presenta, coincidiendo con lo hallado por Lanfri et al. (2013) [63]. En general *Ae. aegypti* no se encuentra por encima de los 2000 msnm (Navarro et al., 1998) [62]. Peterson et al., (2005) [60] también hallaron las variables Elevación del terreno junto con NDVI como las principales predictoras en sus modelos.

YUNGAS	VALLE GRANDE	VALLE GRANDE	VALLE COLORADO	2,18%
			SAN FRANCISCO	1,14%
			VALLE GRANDE	0,93%
			CASPALA	0,62%
			SANTA ANA	0,17%
			PAMPICHUELA	0,04%
	LEDESMA	LIBERTADOR GENERAL SAN MARTIN	LIBERTADOR GENERAL SAN MARTIN	91,03%
			CADLEGUA	80,34%
			FRAILE PINTADO	74,99%
			YUTO	52,29%
			CAMANCITO	42,09%
			CHACICAN	36,32%
			LIBERTAD	15,47%
			BERMEJTO	13,38%
			PAULINA	12,30%
			BANANAL	11,19%
	MAIZ NEGRO	11,00%		
	SANTA BARBARA	SANTA CLARA	EL PIQUETE	48,37%
			PUEBLO LAVAYEN	37,57%
			EL PUERTO	36,32%
			EL TALAR	33,45%
			MANALTO	16,05%
			PALMA SOLA	11,20%
	SAN PEDRO	SAN PEDRO DE JUJUY	SANTA CLARA	8,44%
			SAN PEDRO	86,35%
			LA ESPERANZA	70,15%
			ARRAYANAL	68,92%
			PARAPETI	32,16%
			SAN LUCAS	26,72%
			RODEITO	18,42%
			EL ACHERAL	14,54%
			SAUZAL	14,48%
			DON EMILIO	11,23%
EL PUESTO			10,25%	
ARROYO COLORADO			9,34%	
LA MANGA			9,33%	
SAN ANTONIO			7,72%	
MIRAFLORES			7,38%	
PIEDRITAS			6,58%	
LA MENDIETA			6,08%	
EL QUEMADO	5,19%			
ROSARIO DE RIO GRANDE	4,92%			
PALOS BLANCOS	3,43%			

FIGURA 4.19: Localidades de la Eco-región de las Yungas, con favorabilidad ambiental

En general la cobertura vegetal otorga refugio y alimento a los animales, y muchos autores la toman como referencia. En este trabajo representada por la variable NDVI, resultó ser la tercer estimadora que mejor contribuye al modelado del vector. Kiang et al. (2012) [55], Toure et al. (2008) [61] y Estallo et al. (2008) [6], también incorporaron a sus modelos la variable NDVI, y hallaron que es una importante estimadora debido su fuerte asociación con la temperatura, la precipitación y las propiedades del suelo.

Ambas variables NDVI y temperatura resultaron muy buenas estimadoras en los modelos desarrollados por Estallo et al. (2008) [6] en la ciudad de Orán.

La variable temperatura, ampliamente usada en este tipo de estudios y de gran importancia para el desarrollo del vector (Rose et al., 2000) [48], ha sido en este trabajo una de las que menos aporte ha hecho al modelo, contrario a los hallazgos realizados por parte de Nakhapakorn y Tripathi (2005) [52] quienes encontraron que un incremento en la temperatura y la humedad relativa afectaban la incidencia de dengue. Sin embargo cabe señalar que en las curvas de respuesta de la variable, existe un rango óptimo en cual se puede desarrollar el vector, coincidente con lo hallado por Zambrano et al. (2012) [54] y Rotela et al. (2007) [31].

Las variables Pendiente, Exposición y Precipitación media fueron las que menos contribuyeron al modelo (en el orden menor al 1%).

El test de Jackknife permite comparar el aporte de cada variable, en forma individual al modelo, y cuál es la ganancia del mismo en ausencia de las variables en estudio. En este sentido las variables que mayor información útil presentan son en primer lugar NDVI, coincidente con lo hallado por Peterson et al., (2005) [60], seguida de las variables Precipitación y DEM.

4.5. Conclusión

El modelado de probable distribución para *Ae. aegypti* generado por MaxEnt, con las variables ambientales consideradas presenta un muy buen ajuste, un valor del AUC de 0.994. Los mapas de Favorabilidad Ambiental obtenidos en este capítulo para el vector responden a las condiciones ambientales necesarias para el desarrollo del vector, por cuanto en ellos se puede observar la potencial distribución de vector. Las curvas de respuesta de las variables muestran que existe un rango de valores más óptimos para el desarrollo del vector. Entre las variables que más contribuyen al modelo está la Precipitación Acumulada.

En el mapa de las localidades jujeñas con mayor favorabilidad ambiental se puede observar un patrón de distribución sobre aquellas que se encuentran en las regiones de las Yungas y el Valle, y particularmente aquellas que se encuentran cercanas a la Ruta Nacional 34 (coincidente con los mapas predictivos generados por el SAT/ERDNU (Peralta, 2011 [24])). Estas variables que involucran caminos y rutas de conexión, relacionadas con los movimientos migratorios serán objetos de estudios de futuras investigaciones.

Si bien el modelo se ajusta bastante a la realidad, como se puede observar en las tablas de probabilidad por localidades, dónde por ejemplo aquellas que pertenecen a las eco-regiones de Puna y Quebrada presentan probabilidades muy bajas, en general menores al 10%. Pero también sobrestima algunas áreas, arrojando por ejemplo un riesgo mínimo para algunas localidades dónde no se ha reportado la existencia o aparición del vector en ninguno de sus estadíos, y en otros casos subestimando áreas. Frente a esta situación, es importante mencionar la necesidad de mejorar la cantidad y calidad de los datos de presencia, y de esta manera se evitarán errores que pueden darse por la distribución heterogenea de los mismos.

Los mapas de favorabilidad ambiental obtenidos en este trabajo, dónde se observan las condiciones óptimas para el desarrollo del vector transmisor del dengue constituye una herramienta valiosa para comprender como puede distribuirse la enfermedad, estando presentes las condiciones ambientales óptimas, la población suseptible y la circulación del virus. Estos resultados permitirán tomar medidas de prevención por parte de los organismos de Salud, distribuyendo recursos como personal, insecticidas, maquinarias, enfatizando actividades como el "descacharrado", trabajos de concientización en las diferentes localidades, etc., priorizando los lugares con mayor favorabilidad ambiental, a fin de poder prevenir la enfermedad del dengue en la provincia de Jujuy.

Capítulo 5

Modelos predictivos de Dengue (II)

5.1. Introducción

Como se vió en el capítulo anterior, existen variables macroambiente que en condiciones óptimas determinan la presencia y distribución del vector transmisor de la enfermedad de dengue. Entonces si en una determinada área coexisten: la presencia del vector, la circulación del virus del dengue (representado por casos humanos) y la presencia de una población humana susceptible (no enferma) existe un riesgo asociado a la probabilidad de propagación y contagio de la enfermedad.

El concepto básico de Riesgo está dado por la siguiente fórmula:

$$RIESGO = Amenaza * Vulnerabilidad \quad (5.1)$$

dónde la Amenaza se representa por la presencia del vector y circulación del virus del dengue, y la Vulnerabilidad es la presencia de una población susceptible (Porcasi et al., 2012 [3]).

Para modelar y obtener mapas de distribución de la enfermedad de dengue se suelen emplear variables ambientales relacionadas con la presencia del vector y que han sido utilizadas por varios autores, como el índice diferencial de agua normalizado (NDWI), la cobertura vegetal (NDVI) (Estallo et al., 2008 [6]; Estallo et al., 2012 [56]), la temperatura de brillo (LST) (Dominguez et al., 2000 [47]), imágenes sintéticas derivadas de una imagen Landsat 5TM, como: imágenes buffers de distancias, tasseled cup, entre

otras (Yang et al. 2006 [76]; Rotela et al., 2007 [31]; Rotela et al., 2010 [28]; Vezzani et al. 2001 [77]; Porcasi et al., 2012 [3]).

Nakhapakorn y Tripathi (2005) [52] realizaron una clasificación de las coberturas de suelo y compararon cómo los diferentes ambientes: urbano, agrícolas, áreas de bosque y cuerpos de agua, influyen en la incidencia de dengue.

La variable Demografía tiene que ver con la población expuesta y ha sido utilizada también por Buczak et al. (2012) [78] y Porcasi et al. (2012) [3].

Cabe destacar que las condiciones microambientales dadas por los hábitos de la población de conservar en sus respectivos domicilios recipientes artificiales que acumulen agua, promueven la existencia de criaderos potenciales para el desarrollo de formas inmaduras de *Ae. aegypti*. Además la ineficiente calidad en los servicios públicos, como el abastecimiento de agua potable, tratamiento y disposición final de residuos domiciliarios, conjuntamente con las inadecuadas prácticas de saneamiento domiciliario, favorecen un ambiente propicio para el desarrollo del ciclo biológico del vector (Porcasi et al. 2012) [3].

En este capítulo se emplea un modelado de tipo *Árbol de decisión* (Rotela et al., 2007 [31]), un algoritmo también implementado por Quiñonez (2012) [25] y una Clasificación Supervisada por el método del *Paralelepípedo* con el fin de obtener mapas de riesgo asociados a la probabilidad de ocurrencia de casos de dengue, a escala de localidad (en la ciudad de San Pedro de Jujuy).

5.2. Metodología

5.2.1. Riesgo Urbano

Las variables ambientales empleadas en este modelado, se obtuvieron luego de aplicar algoritmos de bandas sobre la imagen Landsat 5 TM, de esta manera se generaron imágenes sintéticas de relevancia para el estudio epidemiológico.

Modelo de Riesgo Urbano

Siguiendo el criterio de Porcasi et al. (2012) [3] para el diseño de un modelo de Riesgo Urbano (figura 5.1), es necesario tener en cuenta que el mismo depende de la vulnerabilidad (dada por la densidad de la población expuesta) y la amenaza (dada por la presencia del vector y la circulación del virus):

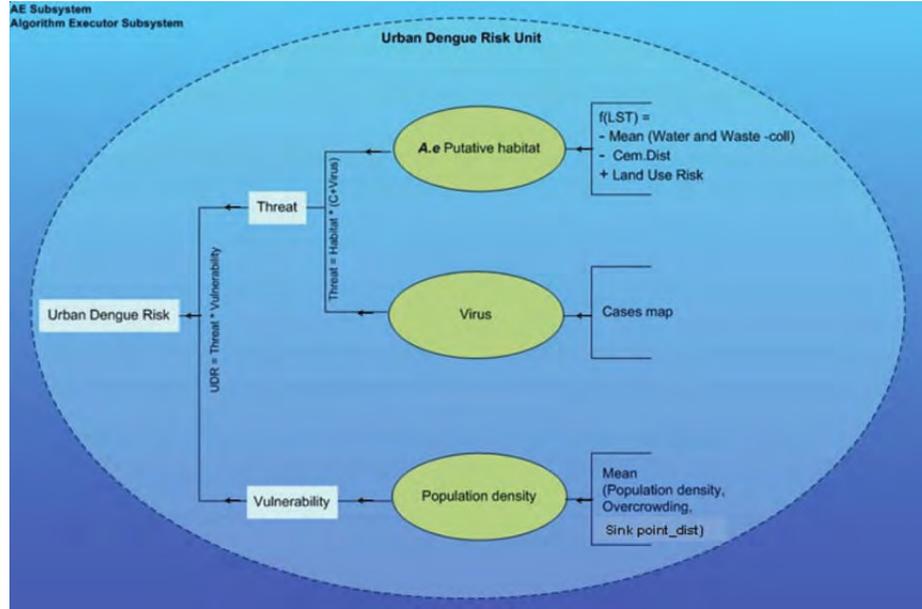


FIGURA 5.1: Diseño de un modelo de Riesgo Urbano. Dónde la Amenaza esta dada por la presencia del vector, y la circulación del virus a través del mapa de los casos humanos, y la Vulnerabilidad esta dada por la densidad de la población. Obtenido desde Porcasi et al. (2012) [3].

5.2.2. Datos

En primer lugar se calibró la imagen Landsat 5 TM, descrita en el Capítulo 2, transformando los niveles digitales (NDs) que son los valores contenidos en cada píxel de la imagen, en unidades físicas siguiendo la bibliografía de calibración para las imágenes Landsat de Chander et al. (2009) [79].

Calibración Radiométrica

La calibración radiométrica de las bandas 1, 2, 3, 4, 5 y 7 convierte los valores de los píxeles en unidades de radiancia absoluta. Aplicando la siguiente fórmula:

$$L_{\lambda} = \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \right) * (Q_{cal} - Q_{calmin}) + LMIN_{\lambda} \quad (5.2)$$

dónde:

L_{λ} = es la Radiancia Espectral recibida por el sensor en la longitud de onda (en: $W/m^2sr\mu m$)

Q_{cal} = es el nivel digital (NDs) a convertir

Q_{calmax} = es el nivel digital máximo calibrado (generalmente =255)

Q_{calmin} = es el nivel digital mínimo calibrado (generalmente =1)

$LMAX_{\lambda}$ = es la radiancia espectral en la banda λ correspondiente a Q_{calmax}

$LMIN_{\lambda}$ = es la radiancia espectral en la banda λ correspondiente a Q_{calmin}

Calibración a Reflectancia

Una vez transformados los valores de NDs a Radiancia Espectral se calcula la Reflectancia total exoatmosférica, mediante la siguiente fórmula:

$$\rho_{\lambda} = \left(\frac{\pi * L_{\lambda} * d}{ESUN_{\lambda} * \cos \theta_s} \right) \quad (5.3)$$

dónde:

ρ_{λ} = es la Reflectancia planetaria al tope de la atmósfera

π = es el Constante matemática igual a 3.14159

L_{λ} = es la Radiancia espectral en la apertura del sensor (en: $W/m^2sr\mu m$)

d = es la Distancia entre la Tierra y el Sol

$ESUN_{\lambda}$ = es la Irradiancia solar exoatmosférica media [$W/ (m^2\mu m)$]

θ_s = es el ángulo cenital solar

Por otra parte la banda térmica (B6) de la imagen Landsat 5 TM se calibra pasando los NDs a Radiancia Espectral y finalmente a Temperatura de Brillo en grados Kelvin. Para esta última conversión se aplica la siguiente ecuación:

$$T = \left(\frac{k_2}{\ln\left(\frac{k_1}{L_{\lambda}} + 1\right)} \right) \quad (5.4)$$

dónde:

T = es la Temperatura de Brillo efectiva medida en el sensor

k_2 = es la Constante de Calibración (k_2)

k_1 = es la Constante de Calibración (k_1)

L_{λ} = es la Radiancia espectral en la apertura del sensor

\ln = es el Logaritmo Natural

Una vez calibrada la imagen se procedió a hacer un recorte de la misma, delimitando la ciudad de San Pedro (fig. 5.2 b), como se observa a continuación:



FIGURA 5.2: Imagen Landsat 5TM, con un recuadro rojo, señalando la localidad de San Pedro de Jujuy (a) (izquierda). Recorte de la imagen Landsat, sobre la localidad de San Pedro (b) (derecha).

5.2.3. Generación de Variables Ambientales

El cálculo de índices es una técnica ampliamente usada en teledetección y permiten discriminar entre coberturas y/o elementos que presenten un comportamiento reflectivo muy distinto entre dos o más bandas (Chuvienco, 1996). Los índices se obtienen a partir de algoritmos aplicados sobre bandas originales de sensores. Entre ellos se encuentran: *índice de Agua (Normalized Difference Water Index: NDWI)*, *índice de Suelo (Normalized Difference Soil Index: NDSI)* e *índice de Vegetación (Normalized Difference Vegetation Index: NDVI)* (Quiñonez, 2012 [25]), o los índices *Tasseled Cap*, o de *Temperatura de Superficie (Land Surface Temperature: LST)* (Sobrino y Raissouni, 2000 [80]).

Usando el software Envi 4.7 se obtuvieron las siguientes imágenes sintéticas a partir de la imagen Landsat 5 TM.

- *Tasseled cup* :

índices de brillo del suelo, representado como: **Brillo**

índice de vegetación verde, representado como: **Verdor**

índice de humedad, representado como: **Humedad**

- *NDVI*
- *NDWI*
- *NDSI*
- *LST*

- *Mapa de Clases* :
 - Ciudad
 - Bosque
 - Arbustos
 - Plazas
 - Suelo Desnudo

- *Imagen buffer* :
 - distancia a Hospitales
 - distancia a Cementerios
 - distancia a Rutas principales
 - distancia a Terminal de omnibus
 - distancia a Colegios
 - distancia a Plazas

El mapa de Clases se realizó mediante el clasificador: (**ISODATA**) utilizando ROI's de entrenamiento y de validación, desde imágenes de alta resolución de Google Earth. Para la validación de las clases obtenidas y estimar la precisión del clasificador, se generaron matrices de confusión y se obtuvo el índice de Kappa. Ambos permiten evaluar categorías en mapas de clasificación y su respectiva correspondencia en el terreno (Hernández-Stefanoni y Ponce-Hernández, 2004 [81]). La matriz de confusión revela la cantidad de píxeles incorrectamente clasificados (error de omisión), como también a que clase han sido incorrectamente asignados (error de comisión) (Chuvieco, 2002 [82]). Mientras que el estadístico Kappa (k), es una medida de la diferencia entre la exactitud lograda por el clasificador automático y una realizada aleatoriamente. El valor del estadístico varía entre 0 y 1. Cuanto más cercano a 1 sea el valor, mayor será la precisión de la clasificación realizada (Chuvieco, 2002 [82]). En este sentido las clases obtenidas, presentaron un Kappa de 0.67, un valor aceptable.

Para la generación de cada imagen buffer se procedió de la siguiente manera: se tomaron puntos – líneas – polígonos de referencia (de hospitales, el cementerio, rutas principales, terminal de omnibus, colegios y plazas) desde una imagen de 2009 de Google Earth (<http://earth.google.com>). Los mismos tienen relación con concentración de personas, posibles sitios de cría del vector, etc. Dichas referencias fueron guardadas en formato *.kml* y con el software *QGIS* fueron transformadas al formato shape (*.shp*). Sobre la imagen Landsat se superpusieron las referencias (*.shp*) y a partir de estas se

generaron los ROI's. Mediante la herramienta: *Crear Zona Buffer desde un ROI's* se elaboraron las imágenes buffer. La imagen buffer es una imagen en formato raster de distancias a las diferentes clases.

A partir de la banda 6 de la imagen Landsat se generó la banda de temperatura (LST) (fig5.3).

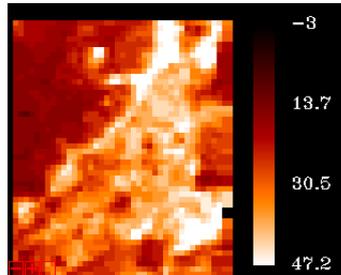


FIGURA 5.3: Imagen LST (banda 6 o térmica de la imagen Landsat). Localidad de San Pedro.

Además se contó con una imagen DEM (fig.5.4), descrita en el Capítulo 2.

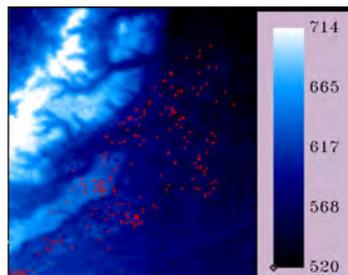


FIGURA 5.4: Imagen DEM. Localidad de San Pedro.

El **NDVI**, fig.5.5 estima la cobertura de vegetación verde y se determina aplicando el siguiente algoritmo sobre las bandas de la imagen:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}, \quad (5.5)$$

dónde

- ρ_{NIR} reflectancia medida en el infrarrojo cercano del espectro electromagnético, correspondiente a la Banda 4 (B4)
- ρ_{RED} reflectancia medida en la banda del rojo del espectro electromagnético, correspondiente a la Banda 3 (B3)

El valor de este índice varía entre -1 y 1 . Los valores negativos del NDVI indican la ausencia de vegetación. El rango común para vegetación verde es $0,2$ a $0,8$. Los valores cercanos a 1 corresponden a la vegetación densa y vigorosa. Los valores positivos justo por encima de cero indican la vegetación con una cubierta escasa, tales como rocas o el suelo al descubierto (Rotela, 2010 [28]).

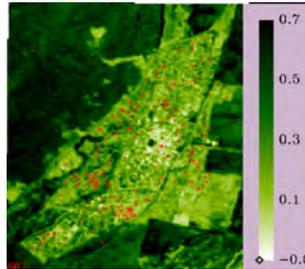


FIGURA 5.5: Imagen NDVI. Localidad de San Pedro.

El **NDWI**: índice normalizado de agua es un buen indicador del contenido de agua y de las condiciones de humedad de la vegetación. Los valores varían entre -1 y 1 . Los cuerpos de agua presentan valores positivos, mientras que la vegetación y el suelo presentan valores cero o negativos. Gao (1996) propuso el cálculo para este índice aplicando la siguiente ecuación:

$$NDWI = \frac{\rho NIR - \rho SWIR}{\rho NIR + \rho SWIR} \quad (5.6)$$

dónde:

- ρNIR reflectancia medida en el infrarrojo cercano del espectro electromagnético, correspondiente a la Banda 4 (B4)
- $\rho SWIR$ reflectancia medida en la banda del rojo del espectro electromagnético, correspondiente a la Banda 5 (B5)

El **NDSI**: índice normalizado de suelo es un indicador de suelos desnudos de vegetación, para la obtención del mismo se aplicó la siguiente ecuación:

$$NDSI = \frac{\rho SWIR - \rho NIR}{\rho SWIR + \rho NIR} \quad (5.7)$$

dónde:

- ρNIR reflectancia medida en el infrarrojo cercano del espectro electromagnético, correspondiente a la Banda 4 (B4)

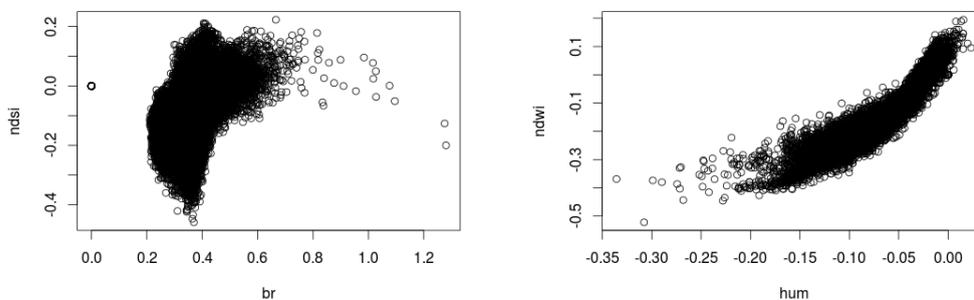


FIGURA 5.6: Gráficos de Correlación entre las variables: ndsi vs. brillo (izq) y humedad vs. ndwi (der). Salidas del programa estadístico **R Studio** .

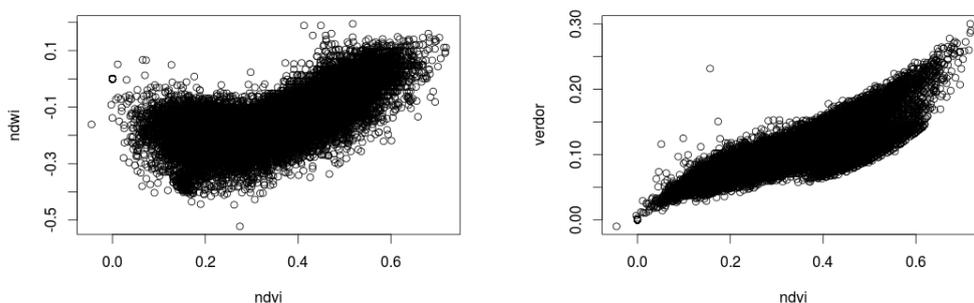


FIGURA 5.7: Gráficos de Correlación entre las variables: ndwi vs. ndvi (izq) y verdor vs ndvi (der). Salidas del programa estadístico **R Studio**.

- ρ_{SWIR} reflectancia medida en la banda del rojo del espectro electromagnético, correspondiente a la Banda 5 (B5)

Con el fin de seleccionar las variables que optimicen el modelo se realizó un análisis de correlación entre aquellas cuya información espectral esten correlacionadas o sean redundantes, para ello se usó el programa estadístico R Studio (097.248). Las variables correlacionadas con un coeficiente r (Pearson) mayor a 0,8 fueron eliminadas. A continuación se muestran algunos gráficos de correlación obtenidos para cada par de variables y las que finalmente se seleccionaron (siguiendo un criterio de menor correlación con respecto a las otras variables) para el análisis.

Teniendo presente que la información de la población, tales como su densidad, su estructura y dinámica contribuyen al estudio de la dispersión de la enfermedad. Entonces desde el Censo de Población y Estadísticas (INDEC 2010), se tomó una capa con formato shape, referida al: “total de población por localidad” (fig. 5.8), fue re proyectada

desde un sistema de coordenadas de proyecciones planas (UTM) a un sistema de coordenadas Geográficas (Lat-Lon), para esto se utilizó la herramienta de ArcCatalog (ArcGIS 9.1). Luego se transformó la capa vectorial (formato shapefile) a raster (con un píxel de 30 mts) (fig. 5.9), para ello se utilizó el programa Quantum Gis 2.2-Valmeria, y se realizó el recorte de la imagen en función de las demás capas ambientales. Finalmente se adjuntó esta capa a las demás, mediante la herramienta *Layer Stacking* usando Envi 4.7.

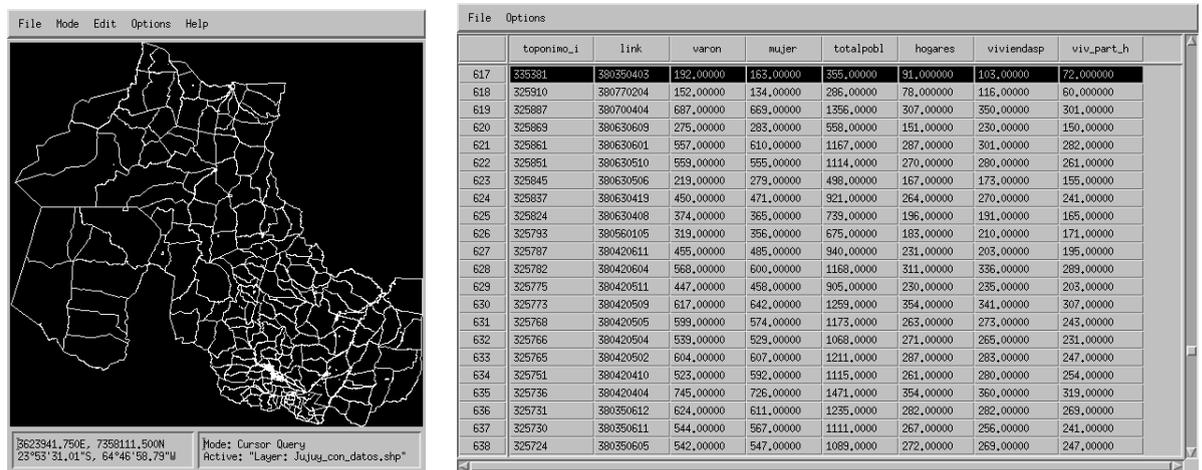


FIGURA 5.8: (Izquierda) Capa shapefile con información del total de la población, desde INDEC 2010. (Derecha) Tabla de atributos de la capa shapefile

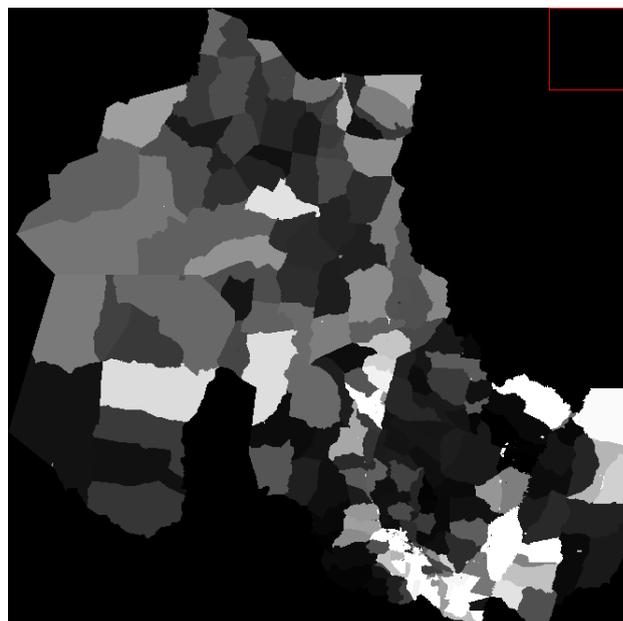


FIGURA 5.9: Capa raster (píxel de 30 mts.) transformada desde la capa shapefile de *Total de la Población*

Luego del análisis de correlación se seleccionaron las variables que se detallan a continuación en el orden que aparecen en la tabla 5.1:

CUADRO 5.1: 14 Variables Ambientales

Bandas	Variable Ambiental
b 1	Cant. Población
b 2	LST
b 3	DEM
b 4	Buffer_Terminal de omnibus
b 5	Buffer_Rutas principales
b 6	NDVI
b 7	NDSI
b 8	Mapa de clases
b 9	Humedad
b 10	Buffer_Hospitales
b 11	Buffer_Colegios
b 12	Buffer_Cementerio
b 13	Brillo
b 14	Buffer_Plazas

5.2.4. Modelo de Regresión Lineal Múltiple

Este análisis permite estudiar la relación entre una variable respuesta Y (variable dependiente) y una o más variables regresoras X (variables independientes o predictoras). Entonces se tomaron las 14 variables seleccionadas anteriormente a los fines de estudiar cuáles se comportan mejor como predictoras de la probabilidad de ocurrencia de casos de dengue en la ciudad de San Pedro de Jujuy. La ecuación del modelo de regresión lineal múltiple (5.8) es la que se detalla a continuación:

$$Y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_k x_{ki} + \varepsilon_i \tag{5.8}$$

Dónde:

- Y_i = es i -ésima observación de la variable dependiente Y
- $X_{1i}, X_{2i}, \dots, X_{ki}$ = es i -ésimo valor de las variables regresoras X_1, X_2, \dots, X_k o independientes
- β_0 = parámetro desconocido que representa la ordenada al origen de la recta (indica el valor esperado de Y cuando $X_1 = 0, X_2 = 0, \dots, X_k = 0$)
- β_1 = parámetros desconocidos que representan la tasa de cambio en Y frente al cambio unitario de X_1, X_2, \dots, X_k respectivamente)
- ε_i = término del error aleatorio

Para este modelo se utilizó el software InfoStat/P (versión Profesional, 2008 [Infostat]) incorporando todas las variables, y se configuró el método de selección: "Stepwise", obteniéndose los siguientes resultados:

```

Análisis de regresión lineal

Variable N    R²    R² Aj    ECMP    AIC    BIC
p            432  0,76    0,75  0,07  36,85  77,54
Selección Stepwise.
    
```

FIGURA 5.10: Análisis de Regresión Lineal

```

Número original de regresoras: 14, regresoras retenidas en el modelo 8
    
```

FIGURA 5.11: Análisis de Regresión Lineal. Total de variables incorporadas en el modelo.

Coefficientes de regresión y estadísticos asociados

Coef	Est.	E.E.	LI(95%)	LS(95%)	T	p-valor	CpMallows	VIF
const	1,36	0,07	1,22	1,50	18,85	<0,0001		
b5	-3,7E-03	1,4E-03	-0,01	-9,3E-04	-2,61	0,0093	14,81	4,70
b2	0,01	2,0E-03	0,01	0,02	5,60	<0,0001	39,29	13,47
b11	-0,01	1,4E-03	-0,01	-4,5E-03	-5,11	<0,0001	34,03	9,95
b12	-0,01	1,9E-03	-0,01	-0,01	-5,10	<0,0001	33,99	12,07
b6	-1,26	0,22	-1,68	-0,83	-5,81	<0,0001	41,72	6,76
b4	-3,7E-03	1,4E-03	-0,01	-9,6E-04	-2,66	0,0080	15,08	7,23
b1	2,7E-04	4,0E-05	1,9E-04	3,5E-04	6,74	<0,0001	53,37	2,10
b7	-0,60	0,27	-1,13	-0,07	-2,23	0,0262	12,97	4,42

Error cuadrático medio: 0,062175

FIGURA 5.12: Análisis de Regresión Lineal. Variables seleccionadas.

La figura 5.10 muestra que la cantidad de puntos analizados fue de 432 (216 positivos y 216 negativos). Una medida de la capacidad predictiva del modelo es el coeficiente de determinación R^2 que relaciona la variación explicada por el modelo con la variación total, y para el modelo se obtuvo un valor de 0,76. El Error Cuadrático Medio de Predicción (ECMP) es una función que permite describir cuán costoso resultará si el pronóstico se aleja una cierta magnitud o distancia del verdadero valor. Para este modelo fue de 0,07. Los índices AIC y BIC (Criterio de información Akaike y criterio de información bayesiano, respectivamente) son dos criterios de uso frecuente para la selección de modelos. Para este modelo fueron de 36,85 y 77,54 respectivamente.

La figura 5.11 muestra la cantidad de variables incorporadas en el modelo, y cuántas han sido seleccionadas.

La figura 5.12 muestra las variables seleccionadas en el modelo de regresión lineal múltiple (según el método de selección: "stepwise") y que tienen un valor $p < 0.05$, es decir presentan relación lineal (positiva o negativa) significativa. Puede observarse además que en este cuadro están los coeficientes de las variables en la columna **Est.**, con los mismos se puede armar la ecuación 5.8.

A partir de estas 8 variables seleccionadas por el modelo de regresión, se analizó estadísticamente la variabilidad de cada una en función de los casos de dengue para modelar a través del *Árbol de Decisión*.

5.2.5. Modelo predictivo: Árbol de Decisión

Sobre la base de las variables predictivas seleccionadas, se construyó un modelo del tipo Árbol de Decisión No jerárquico, una metodología aplicada por Rotela et al. (2011) [83] y Quiñonez (2012) [25], para el estudio del virus Encefalitis de San Luis. Se utilizó el programa Envi 4.7 para la generación del modelo. En esta estructura de árbol no-jerárquico,

cada nodo de decisión resulta en dos ramas. Las expresiones en el clasificador, definen una sola decisión binaria (verdadera o falsa para cada píxel). En cada nueva división en el árbol, se lleva a cabo el mismo ejercicio y el árbol crece hasta llegar a sus nodos terminales es decir, las hojas. Esto se conoce como el enfoque top-down o desde arriba hacia abajo (Min Xu, et al. 2005 [84]), donde cada hoja representa un conjunto único de píxeles, que define la salida de nivel de riesgo.

Usando ENVI 4.7, se realizó un layerstack con las variables ambientales seleccionadas y sobre el mismo, la capa vectorial con los puntos de los casos humanos georreferenciados (el 70 % de los datos para entrenar el modelo, los otros 30 % para la validación). Luego se exportó dicha capa como ROI's a fin de obtener las estadísticas de las bandas que componen el layer, en dichos puntos. A partir de aquí se seleccionaron las variables cuyos rangos logran predecir mejor las probabilidades de ocurrencia de los casos (Rotela, 2010 [28]).

Los nodos o criterios de decisión para la construcción del modelo se muestran en la figura 5.13. Dichos nodos se generaron teniendo en cuenta los rangos constituídos por la media más o menos 1 desvío standar. La asignación de los niveles de riesgo se realizó de manera no jerárquica. Las hojas o salidas del modelo que cumplieron con cuatro criterios de los nodos, se clasifican como de Alto riesgo, con tres nodos de Medio-Alto, con dos nodos de riesgo Medio, mientras que con un nodo significa de Bajo riesgo. Los que no cumplen o no sobreviven a ningún criterio se consideraron de riesgo Nulo.

En la siguiente figura 5.14 se observa un mapa de riesgo para la Localidad de San Pedro, según el modelo.

La figura 5.15 muestra el mapa obtenido del modelo con una capa vectorial superpuesta, de todos los casos humanos georreferenciados

Para la validación del modelo se empleó el 30 % de los casos humanos georreferenciados (ROI's de validación) de la siguiente manera: sobre el mapa de riesgo obtenido a partir del modelo árbol de decisión, se colocó la Roi's de validación y se calcularon las estadísticas. Una manera de corroborar la eficiencia es que el mayor porcentaje de los casos caigan en las áreas de mayor riesgo. Sin embargo existen dos concentraciones de casos a las que no se ajusta el modelo, señaladas en la figura 5.16 con círculos de color violeta, y probablemente en estos puntos existan otras variables no consideradas en este estudio que puedan predecir la ocurrencia de esos casos.

En la figura 5.17 se muestran las estadísticas, revelando que el 31.1 % de los casos caen en zonas consideradas de Alto riesgo (clase 9 figura 5.13), y el 31.3 % aproximadamente, en zonas de riesgo Medio Alto (clases 8, 10, 11 y 13 figura 5.13). La columna DN (clases) comienza a partir de la clase 3, debido a que no existen casos humanos (dentro del 30 %

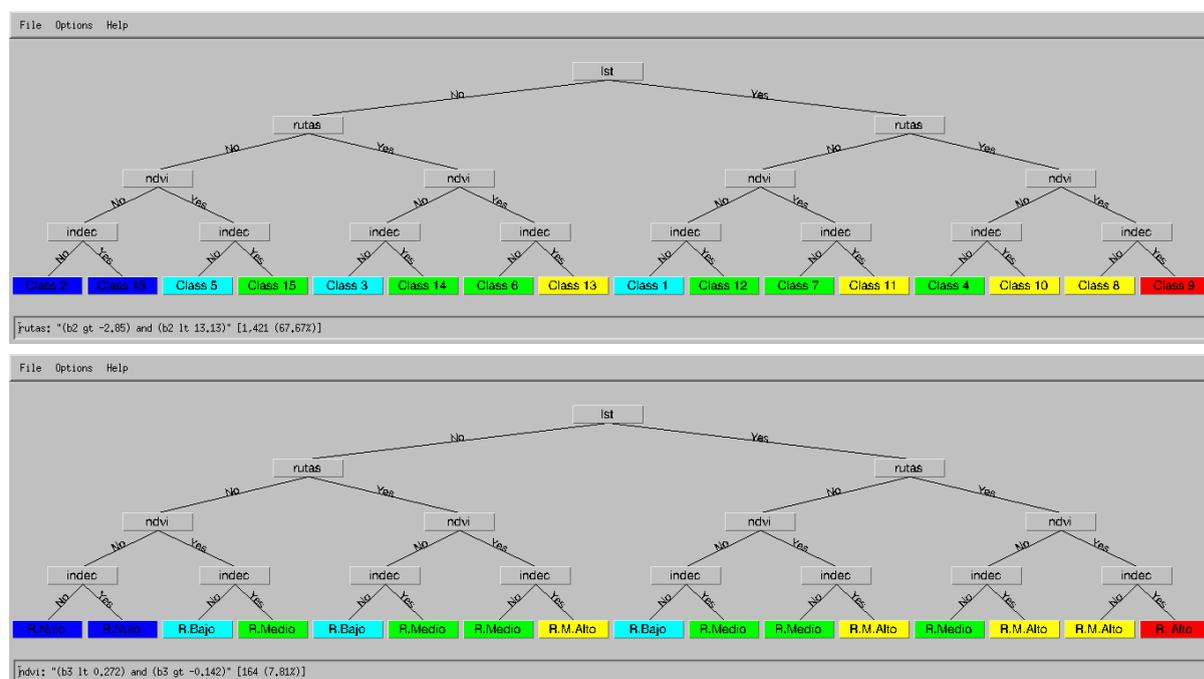


FIGURA 5.13: Modelo Árbol de Decisión de Riesgo de Dengue, con los nodos de decisión generados en función de las variables predictivas seleccionadas. La imagen sup. muestra las diferentes clases obtenidas, y la inf. de acuerdo a los criterios cumplidos, los 5 tipos de riesgos.

seleccionado para la validación) que se hayan encontrado en la clase 1 (Riesgo Bajo) y clase 2 (Riesgo Nulo).

5.2.6. Método del Paralelepípedo

Por otra parte, se utilizó un método de ponderación del riesgo ambiental, a partir de un modelo multifactorial utilizando el método del Paralelepípedo (clasificación supervisada) una metodología aplicada por Rotela et al. (2010) ([28]). Este modelo resulta de gran utilidad cuando se disponen de casos georreferenciados, ya que permite la construcción de un mapa con la distribución de los casos, señalando las zonas con probabilidades de riesgo. La figura 5.18 es una imagen obtenida desde el *Rule Classifier* con los respectivos valores de probabilidad. Esta técnica se llevó a cabo en Envi 4.7.

5.3. Discusión y Conclusión

Existen numerosas variables ambientales que en condiciones óptimas favorecen el desarrollo de *Ae. aegypti*. Es necesario estudiar cada una y seleccionar aquellas que mejor contribuyan en los modelos de predicción de ocurrencia de casos de dengue (Rotela, 2010 [28]), usando análisis de correlación y/o regresiones entre otros.

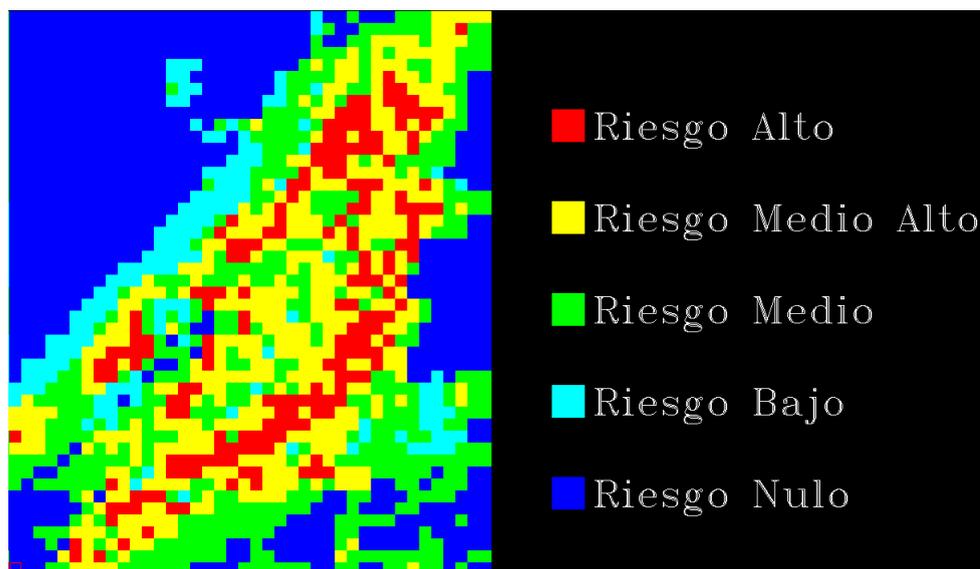


FIGURA 5.14: Mapa de riesgo, para la localidad de San Pedro.

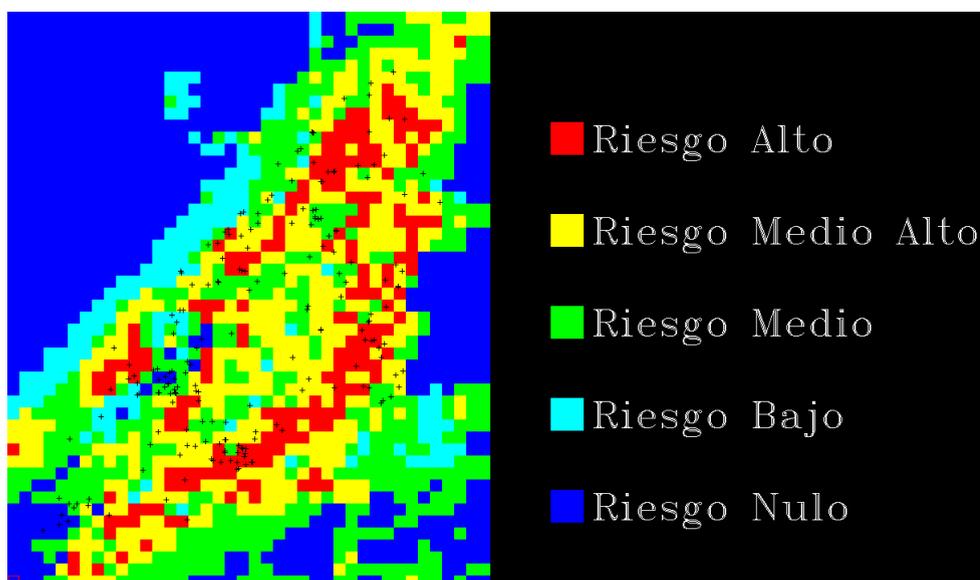


FIGURA 5.15: Mapa de riesgo, para la localidad de San Pedro, conteniendo una capa vectorial de todos los casos humanos georreferenciados, en forma de cruces de color negro.

En este trabajo se realizó en primera instancia un análisis de correlación, y se seleccionó un total de 14 variables. A partir de estas se aplicó un análisis de Regresión Lineal Múltiple que definió ocho variables con capacidad predictiva para el modelo, a continuación se detallan las mismas. El NDVI una variable usada por Estallo et al., (2008) [6]; Estallo et al., (2011) [56], que junto con otras presenta capacidad predictiva. La variable LST usada por Dominguez et al. (2000) [47] revelando que la fluctuación de la población de *Ae. aegypti* en la ciudad de Córdoba, Argentina, se vio influenciada por la temperatura. Las imágenes de distancias a cementerios fue otra variable seleccionada

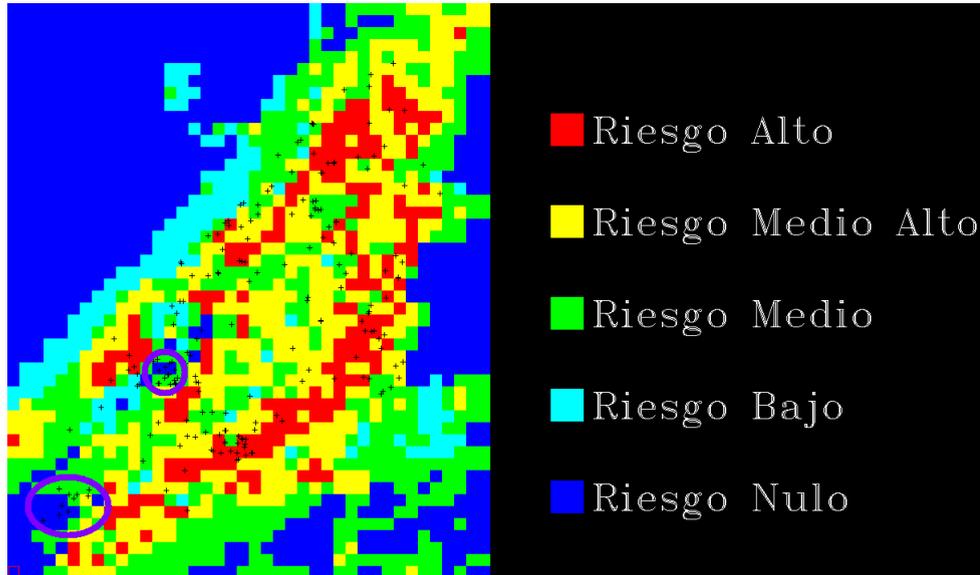


FIGURA 5.16: Mapa de riesgo, señalando con círculos de color morado, dos zonas de concentración de casos humanos que caen en un área de riesgo bajo-nulo.

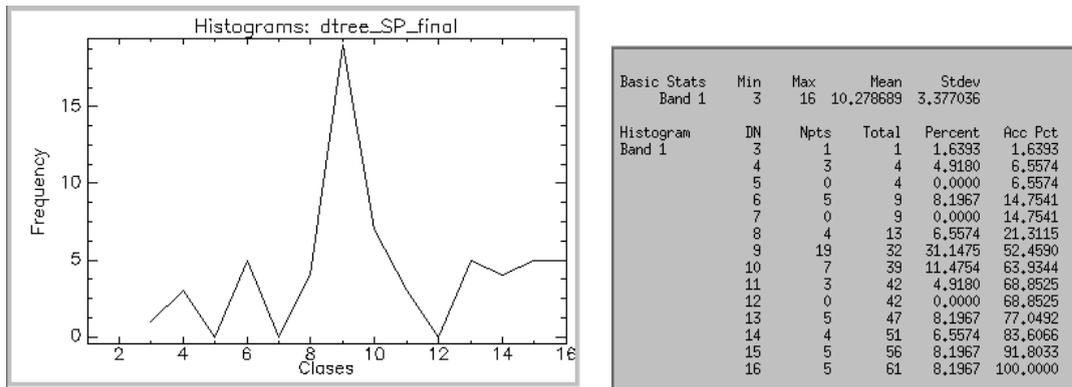


FIGURA 5.17: Estadísticas de las ROI's de validación sobre el mapa de riesgo. Se consideraron las columnas DN (clases) y los porcentajes.

por el análisis de regresión, ya que como reveló el estudio de Vezzani et al. (2004) [51] son sitios dónde se registran frecuentemente criaderos del vector. También fueron seleccionadas las variables NDSI, distancia a colegios (variable incorporada también por Porcasi et al. (2012) [3]) y a rutas principales.

La incorporación de la variable demografía de la población, particularmente la *densidad* o *total de la población* al modelado no jerárquico "Árbol de decisión", resultó de gran importancia, coincidente con lo hallado por Buczak et al. (2012) [78] y Porcasi et al. (2012) [3], como así también la distancia a las rutas principales, ya que es uno de los medios utilizados para las actividades comerciales y dinámica como la migración e inmigración, etc.

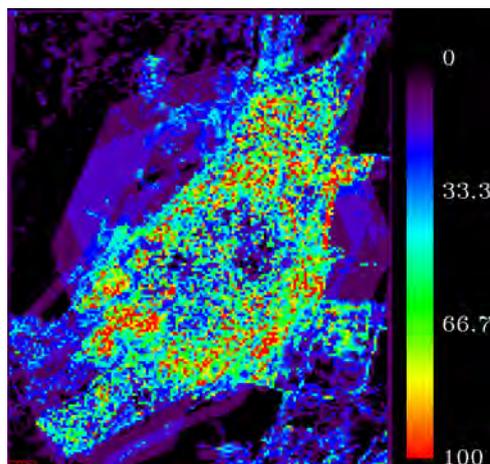


FIGURA 5.18: Mapa de probabilidad, para la localidad de San Pedro.

Los resultados del modelado no jerárquico **Árbol de decisión** se ajustaron bastante al modelo real de distribución de los casos (figura 5.17), sin embargo existen algunas zonas dónde otras variables tal vez puedan predecir mejor la ocurrencia de dichos casos. La temperatura, el índice de vegetación y las precipitaciones son las más frecuentemente usadas para modelar la distribución espacial de la enfermedad a gran escala, pero a nivel urbano es posible encontrar variables asociadas con la actividad de la población, su densidad, sus costumbres entre otras, que pueden contribuir a comprender la dinámica de la enfermedad a escala urbana. Cabe destacar que las condiciones microambientales dadas por los hábitos de la población de conservar en sus respectivos domicilios recipientes artificiales que acumulen agua, promueven la existencia de criaderos potenciales para el desarrollo de formas inmaduras de *Ae. aegypti*. Además la ineficiente calidad en los servicios públicos, como el abastecimiento de agua potable, tratamiento y disposición final de residuos domiciliarios, conjuntamente con las inadecuadas prácticas de saneamiento domiciliario, favorecen un ambiente propicio para el desarrollo del ciclo biológico del vector (Porcasi et al. 2012) [3]. Por otra parte la Clasificación Supervisada por el método del **Paralelepípedo** con el fin de obtener mapas de riesgo asociados a la probabilidad de ocurrencia de casos de dengue, a escala de localidad (en la ciudad de San Pedro de Jujuy), fue una técnica que también se ajustó a los resultados esperados, coincidente con los resultados obtenidos por Rotela et al. (2010) ([28]). Se trata de una opción muy interesante cuando se disponen de casos georreferenciados y se pretende obtener de manera rápida la distribución y las zonas con probabilidad de ocurrencia.

Cabe destacar que en los mapas de riesgo se puede ver que los ambientes Urbanizados son más influyentes y constituyen las zonas de mayor riesgo de dengue, coincidente con los hallazgos de Nakhapakorn y Tripathi (2005) [52], esto tiene relación con los hábitos domiciliarios de *Ae. aegypti*.

Los resultados obtenidos en este trabajo, constituyen una herramienta práctica para la estimación de las áreas de mayor favorabilidad ambiental que promueven el desarrollo del vector a nivel urbano y la probabilidad de riesgo de transmisión de la enfermedad. Con estos resultados se refuerza el uso potencial de los Sensores Remotos y Sistemas de Información Geográficos en la vigilancia epidemiológica y estrategias multidisciplinarias de control. A fin de optimizar los modelos será interesante continuar estudiando y probando variables socio-económicas relacionadas con la transmisión de la enfermedad a nivel urbano (Porcasi et al. 2012 [3]).

Capítulo 6

Conclusiones generales

6.1. Conclusiones

En este trabajo se analizó la distribución espacio-temporal de la enfermedad del Dengue, ocurrida en el brote de 2009 en la localidad de San Pedro de Jujuy. Para esto se aplicaron análisis de correlación espacial entre los casos humanos de dengue (del brote de 2009). El índice de Moran y el Promedio de distancias, revelaron que existe un patrón de agregación espacial entre los casos humanos, con un p-valor de 0.05 y de 0.01 respectivamente. Estos agrupamientos pueden responder a factores entomológicos, eco-epidemiológicos y/o de intervención vectorial.

La herramienta Density Kernel permitió la observación de los cluster espaciales en un mapa de la ciudad de San Pedro. Sobre el mismo se puede conjeturar sobre las variables ambientales que pueden incidir, como por ejemplo la cercanía a las rutas principales. La implementación del test de Knox para analizar el comportamiento espacio temporal del brote de dengue de 2009, resultó de gran ayuda. Se detectaron agrupaciones en espacio y tiempo, esto impulsa la premisa de que las agrupaciones o clusters responden a factores determinados y no al azar.

En este sentido se plantearon consecuentemente modelos capaces de distinguir las variables ambientales que mejor inciden a los fines de elaborar mapas de favorabilidad ambiental (a nivel provincial) y de riesgo (a nivel de localidad).

El modelado distribución para *Ae. aegypti* generado desde MaxEnt, presentó un muy buen ajuste, con un valor del AUC de 0.994. Los mapas de Favorabilidad Ambiental obtenidos revelaron que las zonas de mayor favorabilidad se corresponden con las condiciones ambientales necesarias para el desarrollo del vector, por cuanto en ellos se puede observar la potencial distribución del mismo. Entre las variables que más contribuyen

en el modelo está la Precipitación Acumulada.

Fue posible observar sobre uno de los mapas resultantes que las localidades jujeñas con mayor favorabilidad ambiental siguen un patrón de distribución sobre las que se encuentran en las regiones de las Yungas y el Valle, y particularmente aquellas cercanas a la Ruta Nacional 34. Una variable relacionada con los movimientos migratorios de los seres humanos.

Sobre los mapas de favorabilidad ambiental se observan las zonas que reúnen las condiciones óptimas para el desarrollo del vector transmisor del dengue, esto constituye una herramienta valiosa para comprender como puede distribuirse la enfermedad, estando presentes además una población susceptible y la circulación del virus. Estos resultados permitirán tomar medidas de prevención por parte de los organismos de Salud, distribuyendo recursos como personal, insecticidas, maquinarias, enfatizando actividades como el "descacharrado", trabajos de concientización en las diferentes localidades, etc., priorizando los lugares con mayor favorabilidad ambiental, a fin de poder prevenir la enfermedad del dengue en la provincia de Jujuy.

Cabe destacar además que las zonas con mayor favorabilidad ambiental de la provincia de Jujuy, para el desarrollo del vector coinciden con las zonas de los mapas predictivos, generados por el "Sistema de Alerta Temprana y Estratificación de Riesgo de Dengue Nacional y Urbano: SAT/ERDNU" (Peralta, 2011 [24]).

Para la detección de las zonas de mayor riesgo a nivel de localidad, se observa que la aplicación de un análisis de regresión permitió la selección de variables óptimas, y la aplicación del modelado no jerárquico *Árbol de decisión* arrojó un mapa que se ajusta a la distribución real de los casos humanos del brote ocurrido en la ciudad de San Pedro en el año 2009.

La utilización de los sistemas de información geográfica, permiten hacer un análisis rápido para determinar anticipadamente las intervenciones más adecuadas que eviten o disminuyan el desarrollo de la epidemia. En este estudio se puede apreciar perfectamente las áreas de mayor riesgo de transmisión del virus del dengue, tanto a nivel de provincia como de localidad, siendo estos sectores donde se deben priorizar las estrategias de prevención y control del vector; ya que son los lugares donde puede ser mayor el impacto negativo para la salud de la población. Los resultados expuestos son de gran importancia para la toma de decisiones en salud pública de la provincia y sirven como muestra de metodología alternativa para abordar eventos transmitidos por vectores.

Este trabajo contiene información relevante considerando que puedan ocurrir a futuro, casos graves de dengue.

Considero que las condiciones macroambientales están presentes para que se mantenga y propague la enfermedad de dengue, creo que la clave está en reforzar los hábitos de la población de evitar mantener los sitios de cría del vector en los domicilios.

Es imprescindible reforzar la actividad desde los organismos de salud encargados de promover el control y la remoción de los sitios de cría del vector, como así también promover el conocimiento del ciclo biológico y hábitos del vector, en la población.

6.1.1. Perspectivas a futuro

Teniendo en cuenta que el método de Knox permite identificar patrones espacio-temporales de un evento dado, resulta útil aplicar este método en brotes sucesivos, dentro de la misma localidad y también sobre otras localidades, con el fin de comprender mejor la dinámica de la enfermedad tanto de dengue, como de otras.

Explorar la utilización de imágenes de mayor resolución espacial para abordar los modelos de favorabilidad ambiental para *Ae. aegypti* a fin de obtener mapas de riesgo más precisos.

Probar con otras variables ambientales como la velocidad del viento, o también parámetros poblacionales y comportamentales del vector.

Teniendo en cuenta que la enfermedad de dengue está altamente asociada a las condiciones socio-económicas, como suministro de agua de red, recolección de residuos, hacinamiento, densidad poblacional, etc. (Porcasi et al. 2012), es necesario considerar variables que definan este tipo de relación, a fin de lograr una mayor sensibilidad en la respuesta de los modelos implementados.

Realizar validaciones en series temporales mas largas, con fluctuaciones interanuales, para ir mejorando la calidad y sensibilidad de los modelos predictivos, para lograr hacer una vigilancia activa, es decir buscar y reconocer variables en el ambiente, que permitan tomar acciones preventivas ante los brotes.

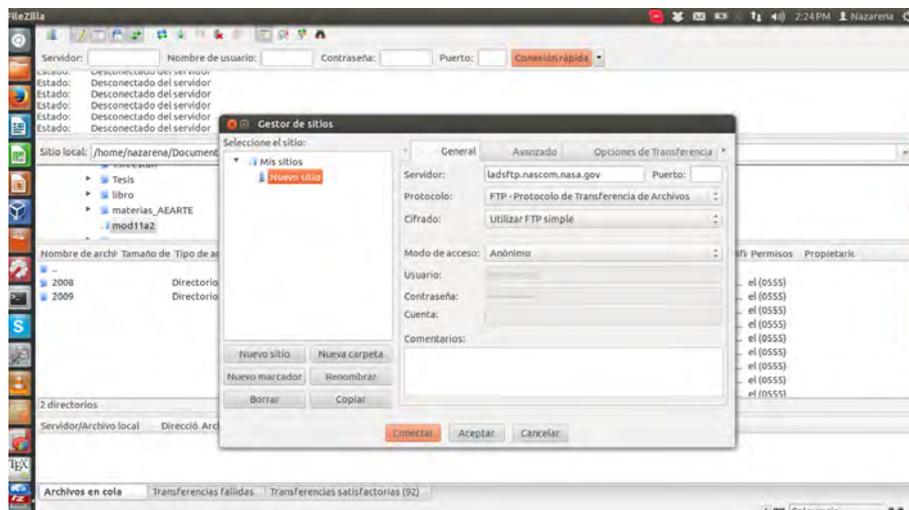
Apéndice A

DESCARGAR SERIES DE PRODUCTOS MODIS DESDE UN FTP

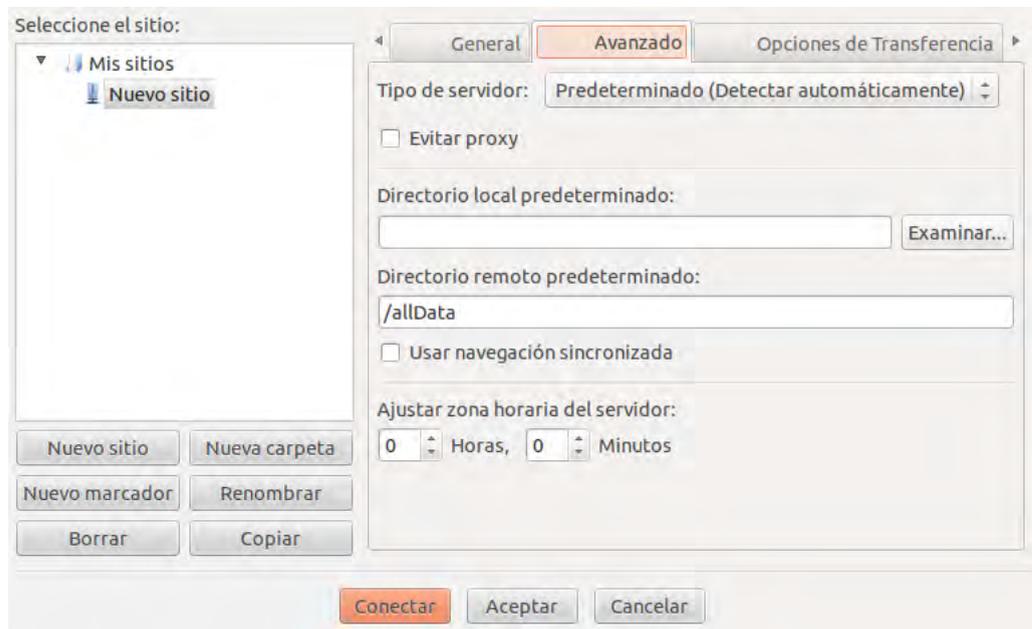
A.1. PARA DESCARGAR UNA SERIE DE PRODUCTOS DE MODIS DESDE UN FTP

A.1.1. DESDE FILEZILLA

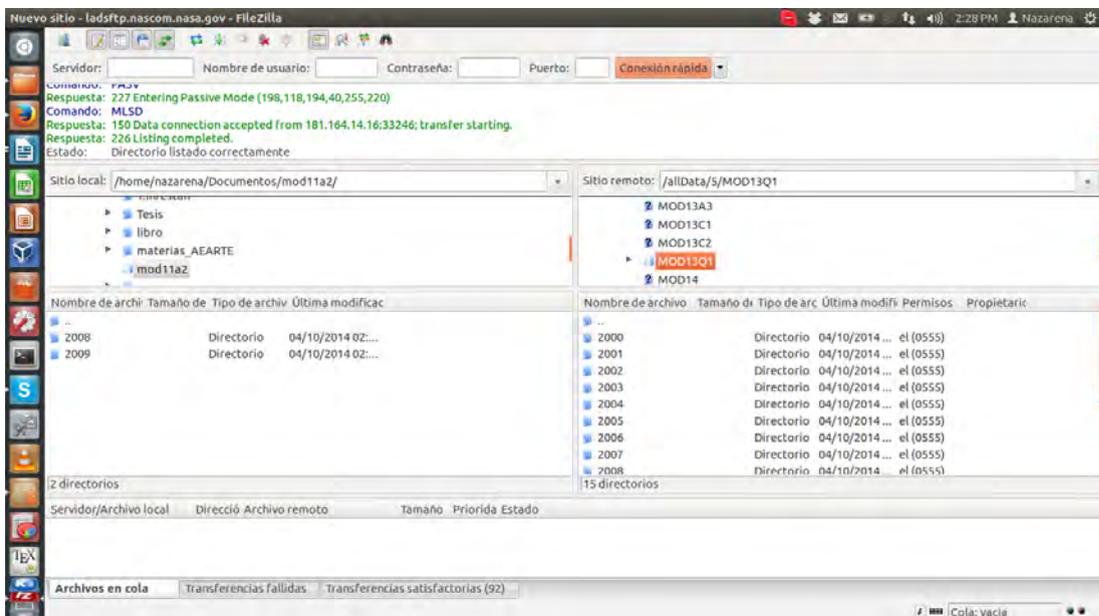
1. DESDE ARCHIVO, SELECCIONAMOS “GESTOR DE ARCHIVOS” >> “NUEVO SITIO” >> “GENERAL” >> SERVIDOR: ladsftp.nascom.nasa.gov



2. DESDE “AVANZADO” >> “DIRECTORIO REMOTO PREDERTMINADO” :
/allData



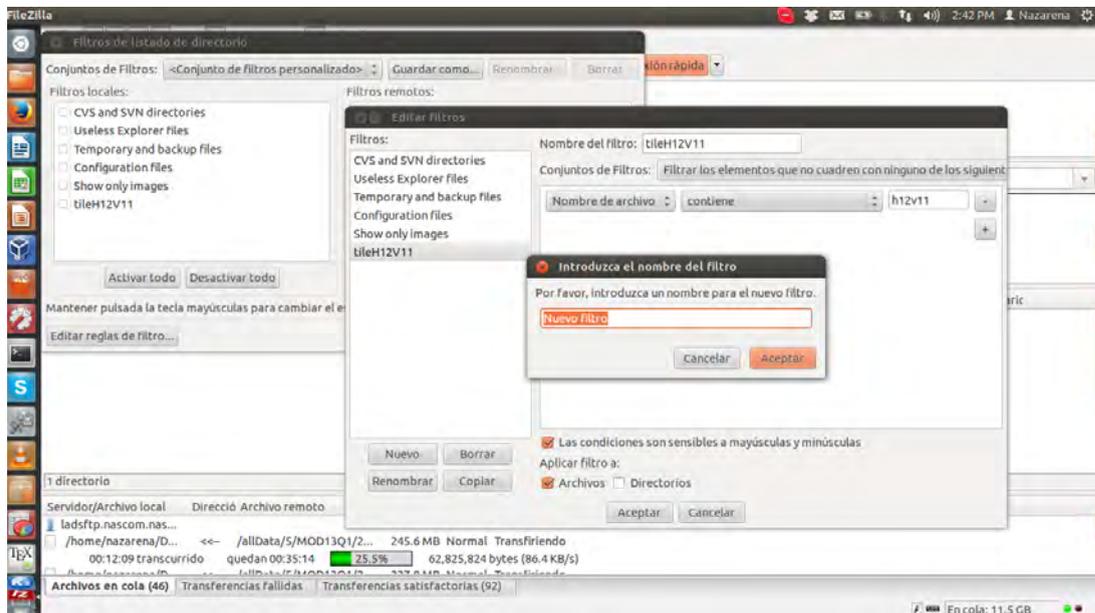
3. >> CONECTAR



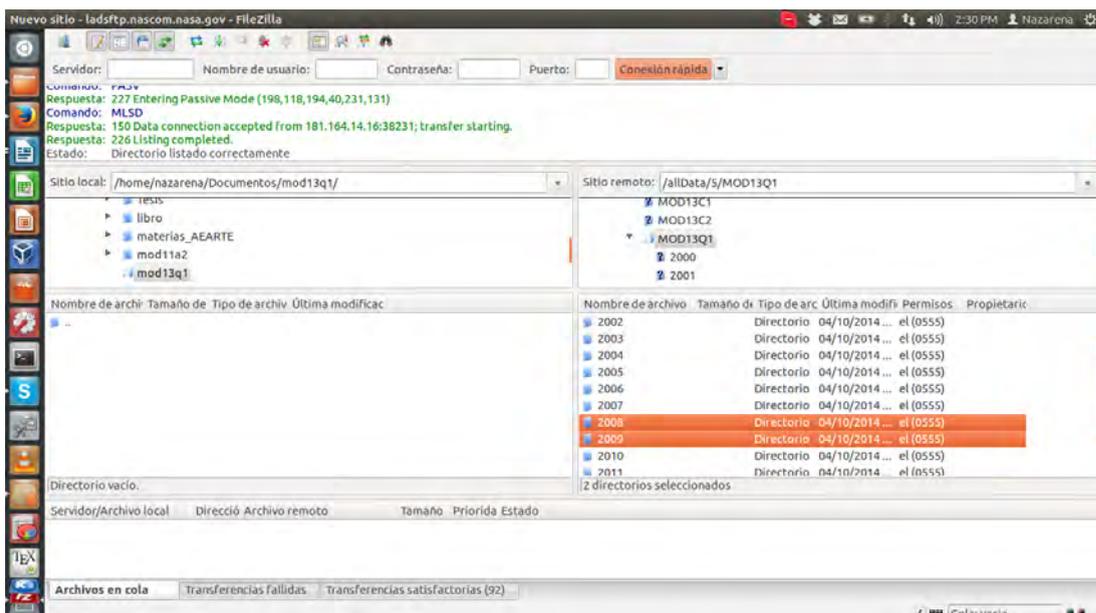
SE DEPLIEGAN TODOS LOS PRODUCTOS, PERO SE SELECCIONA LA CARPETA 5 (.005) ESTA ES LA ÚLTIMA VERSION. LUEGO SE DEBE HACER UN FILTRO

4. VER >> FILTROS DE NOMBRES DE ARCHIVOS >> EDITAR REGLAS DE FILTRO >> NUEVO >> “COLOCAR EL NOMBRE DEL FILTRO” EN >>

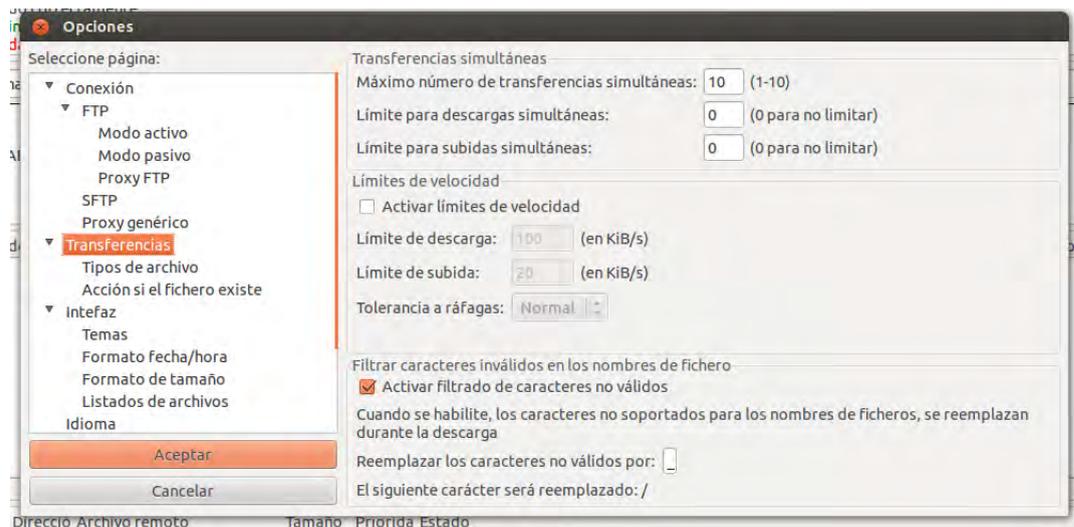
CONJUNTO DE FILTROS” : filtrar los elementos que NO cuadren con ninguno de los siguientes filtros



5. ACTIVAR LUEGO EL FILTRO, PARA ESTE TRABAJO, SE SELECCIONÓ TILE H12 V11. SOBRE LA VENTANA IZQUIERDA SE SELECCIONA LA CARPETA DONDE IRAN LOS ARCHIVOS, MIENTRAS QUE SOBRE LA DERECHA SE ENCUENTRAN LOS ARCHIVOS QUE SE DESEAN DESCARGAR, CON BOTON DERECHO SELECCIONAR “DESCARGAR”



6. SE PUEDE ACELERAR EL PROCESO DE DESCARGA DE 2 (QUE VIENE POR DEFAULT) A 10 EN >> EDICIÓN >> OPCIONES >> TRANSFERENCIA Máximo número de transferencias simultáneas : 10



LINKS DE INTERÉS:

LINK QUE CONTIENE LOS DISTINTOS PRODUCTOS DE MODIS

http://modis.gsfc.nasa.gov/data/dataproduct/dataproducts.php?MOD_NUMBER=05

LINK DONDE SE PUEDE SELECCIONAR EL AREA DE TRABAJO, PARA DESCARGAR IMAGENES

http://reverb.echo.nasa.gov/reverb/#utf8=%E2%9C%93&spatial_map=satellite&spatial_type=rectangle

LINK DONDE SE PUEDE CALCULAR EL “TILE”

<http://landweb.nascom.nasa.gov/cgi-bin/developer/tilemap.cgi>

LINK QUE CONTIENE LA TABLA DE PRODUCTOS DETALLADA

https://lpdaac.usgs.gov/products/modis_products_table

LINK PARA DESCARGAR HERRAMIENTAS PARA LA REPROYECCION DE IMÉGENES MODIS

https://lpdaac.usgs.gov/tools/modis_reprojection_tool

Bibliografía

- [1] Darío Vezzani and Aníbal E Carbajo. *Aedes aegypti*, *aedes albopictus*, and dengue in argentina: current knowledge and future directions. *Memórias do Instituto Oswaldo Cruz*, 103(1):66–74, 2008.
- [2] Wladimir Molina. *Plan Nacional de Prevención y Control del Dengue y fiebre Amarilla. Guía de Usuario ERDNU/HAP*. 2014.
- [3] Ximena Porcasi, Camilo Rotela, María V Introini, Nicolás Frutos, Sofía Lanfri, Gonzalo Peralta, Estefanía A De Elia, Mario A Lanfri, Carlos M Scavuzzo, et al. *An operative dengue risk stratification system in Argentina based on geospatial technology*, volume 6. 2012.
- [4] César Basso. *Abordaje ecosistémico para prevenir y controlar al vector del dengue en uruguay*. *Montevideo, Uruguay: Universidad de la República*, 2010.
- [5] Mirta Eiman, V Introini, and Carlos Ripoll. *Directrices para la prevención y control de aedes aegypti*. *Dirección de Enfermedades Transmitidas por Vectores. Buenos Aires: Ministerio de Salud de la Nación*, 2010.
- [6] Elizabet L Estallo, Mario A Lamfri, Carlos M Scavuzzo, Francisco F Ludueña Almeida, María V Introini, Mario Zaidenberg, and Walter R Almirón. *Models for predicting aedes aegypti larval indices based on satellite images and climatic variables*. *Journal of the American Mosquito Control Association*, 24(3):368–376, 2008.
- [7] S Lanfri, N Frutos, X Porcasi, C Rotela, G Peralta, E De Elia, M Lanfri, and M Scavuzzo. *Algoritmos para el alerta temprana de dengue en un ambiente geomático*. *40JAIIO - CAIS*, pages 089–104, 2011.
- [8] CM Scavuzzo, MA Lamfri, C Rotela, X Porcasi, E Estallo, and Falda del Carmen Espaciales. *Satellite image applied to epidemiology, the experience of the Gulich Institute in Argentina*. 2007.

- [9] Héctor Chiparelli and Felipe Schelotto. Dengue, una enfermedad emergente muy cerca de nuestro país. *Departamento de Bacteriología y Virología. Facultad de Medicina. Montevideo. Uruguay. Disponible en URL: <http://www.infecto.edu.uy/espanol/revisiomentemas/tema10/den6290.htm>*, 12(02), 2010.
- [10] Elodie Descloux, Morgan Mangeas, Christophe Eugène Menkes, Matthieu Lengaigne, Anne Leroy, Temai Tehei, Laurent Guillaumot, Magali Teurlai, Ann-Claire Gourinat, Justus Benzler, et al. Climate-based models for understanding and forecasting dengue epidemics. *PLoS neglected tropical diseases*, 6(2):e1470, 2012.
- [11] Roberto Barrera. *Dinámica del dengue y Aedes aegypti en Puerto Rico*, volume 21. 2010.
- [12] E Martínez. *Dengue y dengue hemorrágico.(Ed.)*, Centro de Impresiones, Universidad Nacional de Quilmes. Buenos Aires (Argentina), 1998.
- [13] Dana A Focks, Eric Daniels, Dan G Haile, James E Keesling, et al. A simulation model of the epidemiology of urban dengue fever: literature analysis, model development, preliminary validation, and samples of simulation results. *American Journal of Tropical Medicine and Hygiene*, 53(5):489–506, 1995.
- [14] R Boffi. Programa de prevención del dengue y control del aedes aegypti. In *Temas de zoonosis y enfermedades emergentes. 2do Congreso Argentino de Zoonosis, 1er Congreso Argentino y Latinoamericano de Enfermedades Emergentes y Asociación Argentina de Zoonosis, editors*, pages 413–419, 1998.
- [15] Héctor Masuh. Re-emergence of dengue in argentina: Historical development and future challenges. 2008.
- [16] Elizabet L Estallo, Francisco F Ludueña-Almeida, Andrés M Visintin, Carlos M Scavuzzo, María V Introini, Mario Zaidenberg, and Walter R Almirón. *Prevention of dengue outbreaks through Aedes aegypti oviposition activity forecasting method*, volume 11. Mary Ann Liebert, Inc. 140 Huguenot Street, 3rd Floor New Rochelle, NY 10801 USA, 2011.
- [17] DJ Gubler and DW Trent. Emergence of epidemic dengue/dengue hemorrhagic fever as a public health problem in the americas. *Infectious agents and disease*, 2(6):383–393, 1993.
- [18] Melinda S Meade. *Medical geography*. Wiley Online Library, 2000.
- [19] DJ Rogers and SE Randolph. Mortality rates and population density of tsetse flies correlated with satellite imagery. 1991.

- [20] KO Pope, EJ Sheffner, KJ Linthicum, CL Bailey, TM Logan, ES Kasischke, K Birney, AR Njogu, and CR Roberts. Identification of central kenyan rift valley fever virus vector habitats with landsat tm and evaluation of their flooding status with airborne imaging radar. *Remote Sensing of Environment*, 40(3):185–196, 1992.
- [21] Louisa R Beck, Bradley M Lobitz, and Byron L Wood. Remote sensing and human health: new sensors and new opportunities. *Emerging infectious diseases*, 6(3):217, 2000.
- [22] Cruz Manuel Aguilar. Satélites artificiales, medicina y epidemiología panorámica: 1er. curso de epidemiología panorámica. *Salus*, 11(3):3–6, 2007.
- [23] Ana Carolina Cuellar. *Uso de Sensores Remotos para la predicción de casos de Malaria en el Departamento Orán, Salta, Argentina. Tesis de Maestría. Universidad Nacional de Córdoba, Argentina.* 2014.
- [24] Gonzalo Sebastián Peralta. *Geomática aplicada a un Sistema de Alerta Temprana. Tesis de Maestría. Universidad Nacional de Córdoba, Argentina.* 2011.
- [25] Facundo Ramón Quiñonez. *Diseño y Desarrollo de Tecnología para la estratificación de riesgo de circulación viral de dengue a nivel urbano. Trabajo Especial en Ciencias de la Computación. Universidad Nacional de Córdoba, Argentina.* 2012.
- [26] JFR Bejarano. Estudio sobre la fiebre amarilla selvática en la república argentina. *Necesidad de una organización de lucha antiamarílica. Subsecretaría de Medicina Sanitaria, y Dirección Nacional de Promoción y Protección de la Salud. Sector Educación para la Salud*, pages 1–31, 1979.
- [27] Annelise Tran, Jacques Gardon, Sacha Weber, and Laurent Polidori. Mapping disease incidence in suburban areas using remotely sensed data. *American journal of epidemiology*, 156(7):662–668, 2002.
- [28] CH Rotela, MO Espinosa, C Albornoz, M Lafaye, JP Lacaux, YM Tourre, MC Vignolles, and CM Scavuzzo. *Desarrollo de mapas predictivos de densidad focal de Aedes aegypti en la ciudad de Puerto Iguazú (Argentina), basados en información ambiental derivada de imágenes Spot 5 HRG1*, volume 30. 2010.
- [29] YL Si, P Debba, AK Skidmore, AG Toxopeus, and L Li. Spatial and temporal patterns of global h5n1 outbreaks. *International Society for Photogrammetry and Remote Sensing*, 2008.
- [30] Michael P Ward and Tim E Carpenter. Analysis of time–space clustering in veterinary epidemiology. *Preventive Veterinary Medicine*, 43(4):225–237, 2000.

- [31] Camilo Rotela, Florence Fouque, Mario Lamfri, Phillipe Sabatier, Virginia Introini, Mario Zaidenberg, and Carlos Scavuzzo. *Space-time analysis of the dengue spreading dynamics in the 2004 Tartagal outbreak, Northern Argentina*, volume 103. Elsevier, 2007.
- [32] J. Fernández Garcete. *Módulo geomático para la integración y el análisis espacio-temporal de casos de brotes epidémicos. Tesis de Maestría. Universidad Nacional de Córdoba, Argentina*. 2014.
- [33] Elizabet Lilia Estallo, Guillermo Más, Carolina Vergara-Cid, Mario Alberto Lanfri, Francisco Ludueña-Almeida, Carlos Marcelo Scavuzzo, María Virginia Introini, Mario Zaidenberg, and Walter Ricardo Almirón. *Spatial patterns of high Aedes aegypti oviposition activity in northwestern Argentina*, volume 8. Public Library of Science, 2013.
- [34] EG Knox and MS Bartlett. The detection of space-time interactions. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 13(1):25–30, 1964.
- [35] Roger J Marshall. A review of methods for the statistical analysis of spatial patterns of disease. *Journal of the Royal Statistical Society. Series A (Statistics in Society)*, pages 421–441, 1991.
- [36] Martin Kulldorff and Ulf Hjalmars. The knox method and other tests for space-time interaction. *Biometrics*, 55(2):544–552, 1999.
- [37] David C Eckley and Kevin M Curtin. Evaluating the spatiotemporal clustering of traffic incidents. *Computers, Environment and Urban Systems*, 37:70–81, 2013.
- [38] Annelise Tran, Xavier Deparis, Philippe Dussart, Jacques Morvan, Patrick Rabarison, Franck Remy, Laurent Polidori, and Jacques Gardon. Dengue spatial and temporal patterns, french guiana, 2001. *Emerg Infect Dis*, 10(4):615–621, 2004.
- [39] Camilo Rotela. *Desarrollo de Modelos e Indicadores Remotos de Riesgo Epidemiológico de Dengue en Argentina. Tesis Doctoral. Universidad Nacional de Córdoba, Argentina*. 2013.
- [40] FN David and DE Barton. Two space-time interaction tests for epidemicity. *British journal of preventive & social medicine*, 20(1):44–48, 1966.
- [41] Jonathan A Patz, WJ Martens, Dana A Focks, and Theo H Jetten. Dengue fever epidemic potential as projected by general circulation models of global climate change. *Environmental Health Perspectives*, 106(3):147, 1998.

- [42] Md Nazmul Karim, Saif Ullah Munshi, Nazneen Anwar, Md Shah Alam, et al. *Climatic factors influencing dengue cases in Dhaka city: a model for dengue prediction*, volume 136. Medknow Publications, 2012.
- [43] Paul Reiter, Sarah Lathrop, Michel Bunning, Brad Biggerstaff, Daniel Singer, Tejpratap Tiwari, Laura Baber, Manuel Amador, Jaime Thirion, Jack Hayes, et al. Texas lifestyle limits transmission of dengue virus. *Emerging infectious diseases*, 9(1):86, 2003.
- [44] Maria G Guzmán, Gissel García, and Gustavo Kourí. El dengue y el dengue hemorrágico: prioridades de investigación. *Rev Panam Salud Pública*, 19(3):204–15, 2006.
- [45] Janet Franklin. *Mapping species distributions: spatial inference and prediction*. Cambridge University Press, 2010.
- [46] DA Focks, DG Haile, E Daniels, and GA Mount. Dynamic life table model for aedes aegypti (diptera: Culicidae): simulation results and validation. *Journal of medical entomology*, 30(6):1018–1028, 1993.
- [47] Martha C Domínguez, FF Ludueña Almeida, and Walter R Almirón. *Dinámica poblacional de Aedes aegypti (Diptera: Culicidae) en Córdoba capital*, volume 59. 2000.
- [48] Joan B Rose, Scott Daeschner, David R Easterling, Frank C Curriero, Subhash Lele, and Jonathan A Patz. Climate and waterborne disease outbreaks. *Journal-American Water Works Association*, 92(9):77–87, 2000.
- [49] LM Rueda, KJ Patel, RC Axtell, and RE Stinner. Temperature-dependent development and survival rates of culex quinquefasciatus and aedes aegypti (diptera: Culicidae). *Journal of medical entomology*, 27(5):892–898, 1990.
- [50] Marcelo Otero, Hernán G Solari, and Nicolás Schweigmann. A stochastic population dynamics model for aedes aegypti: formulation and application to a city with temperate climate. *Bulletin of mathematical biology*, 68(8):1945–1974, 2006.
- [51] Darío Vezzani, Stella Maris Velázquez, and Nicolás Schweigmann. Seasonal pattern of abundance of aedes aegypti (diptera: Culicidae) in buenos aires city, argentina. *Memórias do Instituto Oswaldo Cruz*, 99(4):351–356, 2004.
- [52] Kanchana Nakhapakorn and Nitin Kumar Tripathi. An information value based analysis of physical and climatic factors affecting dengue fever and dengue haemorrhagic fever incidence. *International Journal of Health Geographics*, 4(1):1, 2005.

- [53] Myriam Gharbi, Philippe Quenel, Joël Gustave, Sylvie Cassadou, Guy La Ruche, Laurent Girdary, and Laurence Marrama. Time series analysis of dengue incidence in guadeloupe, french west indies: forecasting models using climate variables as predictors. *BMC infectious diseases*, 11(1):1, 2011.
- [54] LI Zambrano, SZ Reyes García, M Sierra, R Kafati, and Alfonso Javier Rodríguez Morales. *Potential impacts of climate variability on Dengue Hemorrhagic Fever in Honduras, 2010*. Tropical Biomedicine Vol. 29 No. 4 (Dic. 2012), 2012.
- [55] RK Kiang and RP Soebiyanto. Mapping the risks of malaria, dengue and influenza using satellite data. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1:83–86, 2012.
- [56] Elizabet Lilia Estallo, Francisco Felipe Ludueña-Almeida, Andrés Mario Visintin, Carlos Marcelo Scavuzzo, Mario Alberto Lamfri, María Virginia Introini, Mario Zaidenberg, and Walter Ricardo Almirón. *Effectiveness of normalized difference water index in modelling Aedes aegypti house index*, volume 33. Taylor & Francis, 2012.
- [57] Jonathan A Patz and Sara H Olson. Climate change and health: global to local influences on disease risk. *Annals of Tropical Medicine and Parasitology*, 100(5-6): 535–549, 2006.
- [58] S Hales, SJ Edwards, RS Kovats, et al. Impacts on health of climate extremes. *Climate change and health: risks and responses*. Geneva, World Health Organization, 2003.
- [59] Marianne J Hopp and Jonathan A Foley. *Global-scale relationships between climate and the dengue fever vector, Aedes aegypti*, volume 48. Springer, 2001.
- [60] A Townsend Peterson, Carmen Martínez-Campos, Yoshinori Nakazawa, and Enrique Martínez-Meyer. Time-specific ecological niche modeling predicts spatial dynamics of vector insects and human dengue cases. *Transactions of the Royal Society of Tropical Medicine and Hygiene*, 99(9):647–655, 2005.
- [61] YM Tourre, Lionel Jarlan, JP Lacaux, CH Rotela, and M Lafaye. *Spatio-temporal variability of NDVI–precipitation over southernmost South America: possible linkages between climate signals and epidemics*, volume 3. IOP Publishing, 2008.
- [62] Juan Carlos Navarro. *Fauna de mosquitos (Diptera: Culicidae) del Parque Nacional Cerro El Copey y nuevos registros para La Isla de Margarita, Venezuela*, volume 13. 1998.

- [63] M Lamfri, S Quevedo, E Solano, C Rotela, and M Scavuzzo. *Análisis regional de la difusión del dengue en Sudamérica.[Internet]*. 2013.
- [64] Aníbal Eduardo Carbajo, Nicolás Schweigmann, Susana Isabel Curto, Alicia De Garín, and Rubén Bejarán. *Dengue transmission risk maps of Argentina*, volume 6. Wiley Online Library, 2001.
- [65] Sunil Kumar and Thomas J Stohlgren. Maxent modeling for predicting suitable habitat for threatened and endangered tree *canacomyrca monticola* in new caledonia. *Journal of Ecology and the Natural Environment*, 1(4):094–098, 2009.
- [66] Francisco Xavier Niell Castanera and José Antonio Carreira de la Fuente. *Análisis de componentes principales sobre datos multiespectrales Landsat-TM e interpretación de cubiertas vegetales en las Sierras de Tejeda y Almijara*. Universidad de Málaga, Servicio de Publicaciones, 1995.
- [67] Steven J Phillips, Miroslav Dudík, and Robert E Schapire. A maximum entropy approach to species distribution modeling. In *Proceedings of the twenty-first international conference on Machine learning*, page 83. ACM, 2004.
- [68] Steven J Phillips, Robert P Anderson, and Robert E Schapire. Maximum entropy modeling of species geographic distributions. *Ecological modelling*, 190(3):231–259, 2006.
- [69] Jane Elith, Steven J Phillips, Trevor Hastie, Miroslav Dudík, Yung En Chee, and Colin J Yates. A statistical explanation of maxent for ecologists. *Diversity and Distributions*, 17(1):43–57, 2011.
- [70] Pilar A Hernandez, Catherine H Graham, Lawrence L Master, and Deborah L Albert. The effect of sample size and species characteristics on performance of different species distribution modeling methods. *Ecography*, 29(5):773–785, 2006.
- [71] Steven J Phillips and Miroslav Dudík. Modeling of species distributions with maxent: new extensions and a comprehensive evaluation. *Ecography*, 31(2):161–175, 2008.
- [72] Andrey Bethânia Rodrigues Ramos. *Aplicación de modelos de distribución geográfica para la conservación y reintroducción en el hábitat natural de "Lychnophora ericoides": Especie amenazada de extinción en los cerrados (sabanas brasileñas)*. PhD thesis, Universidad Internacional de Andalucía, 2011.
- [73] Robert P Anderson, Daniel Lew, and A Townsend Peterson. Evaluating predictive models of species' distributions: criteria for selecting optimal models. *Ecological modelling*, 162(3):211–232, 2003.

- [74] Alan H Fielding and John F Bell. A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environmental conservation*, 24(01):38–49, 1997.
- [75] Steven Phillips. A brief tutorial on maxent. *AT&T Research*, 2005.
- [76] Guo-Jing Yang, Penelope Vounatsou, Marcel Tanner, Xiao-Nong Zhou, and Jürg Utzinger. *Remote sensing for predicting potential habitats of Oncomelania hupensis in Hongze, Baima and Gaoyou lakes in Jiangsu province, China*, volume 1. Università degli studi di Napoli Federico II; Global Network of Geospatial Health (GnosisGIS), 2006.
- [77] Darío Vezzani, Stella M Velázquez, Silvina Soto, and Nicolás J Schweigmann. Environmental characteristics of the cemeteries of buenos aires city (argentina) and infestation levels of aedes aegypti (diptera: Culicidae). *Memórias do Instituto Oswaldo Cruz*, 96(4):467–471, 2001.
- [78] Anna L Buczak, Phillip T Koshute, Steven M Babin, Brian H Feighner, and Sheryl H Lewis. A data-driven epidemiological prediction method for dengue outbreaks using local and remote sensing data. *BMC medical informatics and decision making*, 12(1):124, 2012.
- [79] Gyanesh Chander, Brian L Markham, and Dennis L Helder. *Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors*, volume 113. Elsevier, 2009.
- [80] JA Sobrino and N Raissouni. *Toward remote sensing methods for land cover dynamic monitoring: application to Morocco*, volume 21. Taylor & Francis, 2000.
- [81] J Luis Hernandez-Stefanoni and Raul Ponce-Hernandez. Mapping the spatial distribution of plant diversity indices in a tropical forest using multi-spectral satellite image classification and field measurements. *Biodiversity & Conservation*, 13(14):2599–2621, 2004.
- [82] Emilio Chuvieco. *Teledetección ambiental: la observación de la tierra desde el espacio*. Number G70. 4. C58 2002. 2002.
- [Infostat] Grupo Infostat. *InfoStat software estadístico InfoStat versión 2008, Manual de usuario, Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina, 2008.(Consultado el 13 de mayo de 2015)*, volume 13.
- [83] Camilo Rotela, Lorena Spinsanti, Mario Lamfri, Marta Contigiani, Walter Almirón, and Carlos Scavuzzo. *Mapping environmental susceptibility to Saint Louis encephalitis virus, based on a decision tree model of remotely sensed data*, volume 6.

Università degli studi di Napoli Federico II; Global Network of Geospatial Health (GnosisGIS), 2011.

- [84] Min Xu, Pakorn Watanachaturaporn, Pramod K Varshney, and Manoj K Arora. *Decision Tree Regression for soft classification of remote sensing data*, volume 97. Elsevier, 2005.