



**UNIVERSIDAD CÉSAR VALLEJO**

**FACULTAD DE INGENIERÍA Y ARQUITECTURA**  
**ESCUELA PROFESIONAL DE INGENIERÍA AMBIENTAL**

**Uso de datos satelitales para determinar el modelado de la  
temperatura adecuado ante fenómenos naturales en Vilque -  
Puno, 2018**

TRABAJO DE INVESTIGACIÓN PARA OBTENER EL GRADO ACADÉMICO DE:

Bachiller en Ingeniería Ambiental

**AUTORES:**

Ortega Mamani, Manuel Alonso (ORCID: 0000-0001-6971-1327)

Rios Bujaico, Luis Andrés (ORCID: 0000-0003-4729-50 05)

Valdivieso Hernández, Ketty Danae (ORCID: 0000-0001-6751-9630)

**ASESOR:**

Mgr. Baldárrago Baldárrago, Jorge Luis Aníbal (ORCID: 0000-0002-7051- 2234)

**LÍNEA DE INVESTIGACIÓN:**

Gestión de Riesgos y Adaptación al Cambio Climático

LIMA - PERÚ

2019

## **Dedicatoria**

A nuestros padres por habernos inculcado valores como la perseverancia y la responsabilidad en cada uno de nuestros actos, motivándonos a concretar nuestras metas.

## **Agradecimiento**

A nuestros padres por su apoyo incondicional durante estos años y a nuestro asesor Mgtr. Jorge Luis Aníbal Baldárrago Baldárrago, quien con su consejo y guía constante supo elevar nuestros intereses para la síntesis de nuestro trabajo de investigación.

## Índice de contenidos

Dedicatoria	ii
Agradecimiento	iii
Índice de figuras	vi
RESUMEN	ix
ABSTRACT	x
I. INTRODUCCIÓN	1
II. MARCO TEÓRICO	4
III. METODOLOGÍA	11
3.1. Tipo y diseño de investigación	11
3.2. Variables y operacionalización	12
3.3. Población, muestra y muestreo	12
3.4. Técnicas e instrumentos de recolección de datos	13
3.5. Procedimientos	15
3.6. Método de análisis de datos	16
3.7. Aspectos éticos	17
IV. RESULTADOS	18
V. DISCUSIÓN	38
VI. CONCLUSIONES	43
VII. RECOMENDACIONES	44
REFERENCIAS	45
ANEXOS	49

## Índice de tablas

Tabla 1. Estaciones Meteorológicas .....	18
Tabla 2. Resultados del modelado por Banda 10.....	19
Tabla 3. Resultados del modelado por Banda 11 .....	20
Tabla 4. Variación de medias de los modelos.....	28
Tabla 5. Significancias de la normalidad .....	30
Tabla 6. R cuadrados de la Regresión Lineal Múltiple.....	31
Tabla 7. Coeficientes del modelo de Regresión Lineal Múltiple.....	31
Tabla 8. R cuadrados de la Regresión Lineal Simple .....	32
Tabla 9. Significancias de coeficientes de la Regresión Lineal Simple .....	33
Tabla 10. Comparación de R cuadrados de los modelos de R.L.S y R.L.M.....	33
Tabla 11. Comparación de análisis ANOVA en los modelos de R.L.S y R.L.M. ....	34
Tabla 12. Variación de medias de las Bandas.....	35
Tabla 13. Valores medios de Emisividad.....	37

## Índice de figuras

Figura 1. Diagrama de generación de raster de temperatura.....	25
Figura 2. Diagrama de la Temperatura Superficial con imágenes satelitales.....	27
Figura 3. Barras de la variación de medias de los modelos .....	29
Figura 4. Barras de la variación de medias de las Bandas.....	36

## RESUMEN

Este trabajo de investigación se realizó para el distrito de Vilque, provincia y departamento de Puno - 2018. El objetivo fue determinar el modelo apropiado para la predicción de la temperatura ante fenómenos naturales. Se tocaron los temas de teledetección, pues se trabajó con imágenes satelitales. La investigación es aplicada de tipo explicativa, con diseño no experimental y un muestreo no probabilístico con muestras representativas de 46 estaciones meteorológicas durante el año 2018.

Para ello se obtuvo una base de datos hidrometeorológicos que registran valores de temperatura, y se empleó la regresión lineal múltiple y simple para generar 12 ecuaciones, una por mes del año 2018, y estos modelos se validaron con 13 estaciones. Además, en el análisis de las imágenes satélite, se les tuvo que recortar las zonas con alta presencia de nubes para su posterior procesamiento.

Finalmente se obtuvo una variación de medias en promedio de 1.3 para el modelo de Regresión Lineal Simple, de 5.9 para la banda 11 y de 6.3 para la banda 10, con lo cual concluimos que el modelo adecuado viene siendo la Regresión Lineal Simple.

Palabras claves: Regresión Lineal Simple, Regresión Lineal Múltiple, Teledetección, Teoría de Planck, Sistemas de Información Geográfica.

## **ABSTRACT**

This research work was conducted for the district of Vilque, province and department of Puno - 2018. The objective was to determine the appropriate model for temperature prediction in the face of natural phenomena. Remote sensing issues were touched upon, since we worked with satellite images. The research is applied of explanatory type, with non-experimental design and non-probabilistic sampling with representative samples of 46 meteorological stations during 2018.

For this purpose, a hydrometeorological database recording temperature values was obtained, and multiple and simple linear regression was used to generate 12 equations, one per month of 2018, and these models were validated with 13 stations. In addition, in the analysis of the satellite images, the areas with high cloud presence had to be cut out for further processing.

Finally, we obtained an average mean variation of 1.3 for the Simple Linear Regression model, 5.9 for band 11 and 6.3 for band 10, which leads us to conclude that the adequate model is the Simple Linear Regression.

Keywords: Simple Linear Regression, Multiple Linear Regression, Remote Sensing, Planck's Theory, Geographic Information Systems.



## I. INTRODUCCIÓN

La realidad problemática del presente estudio se centra en la falta de información que existe y no permite ejecutar un plan de prevención eficaz frente a los desastres naturales que se vienen presentando año tras año con mayor intensidad. El portal web British Broadcasting Corporation (BBC) (2018), realizó un recuento de los desastres naturales que sobresalieron el año pasado entre los que destacan la alta temperatura en varios países de Europa, lluvias extremas en China, el incendio forestal en California, entre otros. Este último aconteció “en noviembre del año pasado y fue el más catastrófico en la historia de California, y el más mortífero en los últimos 90 años.” Asimismo, a nivel nacional, SENAMHI (2017), en el mes de diciembre, registró mayor frecuencia de lluvias intensas en las regiones andina y amazónica del país; además pronosticaron que los valores de temperatura mínima del aire serían ligeramente más cálidas, mientras que los valores de temperatura máxima serían más frías, a excepción de la Región Puno, donde es más probable un escenario con temperaturas máximas sobre lo normal.

Es por ello que nuestro trabajo plantea utilizar métodos para elaborar mapas de temperatura real mensual, con la finalidad de poder utilizarla como fuente confiable y fidedigna de manera que se pueda elaborar un plan de prevención que nos permita mermar con los daños ambientales, económicos y sociales.

Es así que la investigación pretende resolver el siguiente problema general ¿cuál de los modelos es el mejor predictor de la temperatura ante fenómenos naturales en Vilque - Puno, 2018?, y los problemas específicos ¿qué banda de la data satelital es la ideal para el modelado de la temperatura ante fenómenos naturales en Vilque-Puno, 2018? y ¿qué valores de la emisividad se obtienen en la data satelital para el modelado de la temperatura ante fenómenos naturales en Vilque-Puno, 2018?

La investigación se justifica por su potencial aporte a nivel social debido a su trascendencia para el desarrollo de las actividades económicas, ganaderas y agrícolas, pues se beneficiarán a 2 761 pobladores (Censo 2017 - INEI) del Distrito de Vilque en el Departamento y Provincia de Puno, a las

cuales, mediante este trabajo de investigación, se podrán emitir alertas sobre si hay condiciones adversas en la atmósfera producto de la temperatura del aire, de modo que los pobladores puedan realizar labores culturales en sus parcelas de cultivo, áreas de cobertizos y/o en sus viviendas para mitigar o menguar el daño producido por el evento atmosférico, es así que se realizarán productos más confiables para la toma de decisiones en políticas de gestión de riesgos, brindando servicios que aporten al fortalecimiento de las capacidades de la población; a nivel práctico, el distrito de Vilque es vulnerable a veranillos o sequías, el cual a través de un monitoreo de las condiciones atmosféricas, con especial tratamiento en la temperatura, y con criterios de procesos normalizados, se puede dar aviso a las autoridades para que se tomen medidas preventivas y puedan emitir alertas a la población, así también, la generación de data grillada de temperatura, como producto final puede ayudar al monitoreo, como insumo ayuda a modelar otros eventos climáticos como las heladas, granizadas, y sus impactos en la agricultura y ganadería, actividades que realiza la población como medio de obtención económica para cubrir sus necesidades básicas entre otros; a nivel teórico, con esta investigación se quiere poner de manifiesto el uso de data satelital como fuente alternativa de datos meteorológicos, ante la escasez y mucha veces al alto costo en instalación y mantenimiento de una red de estaciones, adecuadamente distribuidas, es así que se abordarán temas relacionados a la teledetección y como la carrera espacial ha traído consigo una nueva gama de tecnologías al servicio del de sociedad civil; a nivel metodológico a partir de los conocimientos y antecedentes podría ayudar esta investigación a que haya nuevas estrategias que podrían ayudar a estar preparados ante cualquier eventualidad natural.

Por lo tanto, se tiene como objetivo general determinar el modelo apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018 y como objetivos específicos son determinar la banda de la data satelital ideal para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018 y calcular los valores de la emisividad que se obtienen en la data satelital para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018.

De esta manera se pretende verificar la hipótesis general: La regresión lineal será el modelo más apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018, y las hipótesis específicas: la banda 11 del infrarrojo térmico de la data satelital será la ideal para el modelado de temperatura ante fenómenos naturales en Vilque - Puno, 2018, la emisividad óptima se encuentra en el rango de 0.95 -1 para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018.

## II. MARCO TEÓRICO

Los principales antecedentes para el estudio son:

AGUILAR; MORA y VARGAS (2014), en su investigación *Surface temperatura sensor tirs/landsat-8: Methodology and Applications*, donde propone contribuir en la difusión y la aplicación de geo que muestran la temperatura de la superficie para obtener fórmula Celsius infrarrojo térmico Sensor TIRS/Landsat-8, la tira 10 en un entorno GIS (sistema de información geográfica). Se basó en el detalle las fórmulas de los coeficientes de calibración radiométrica para obtener temperaturas Celsius, la gama de infrarrojo térmico, el satélite Landsat-8 con una resolución espacial de 30 metros. La población de estudio fue en el Municipio de Vitória, Brasil, la muestra estuvo conformada en consultas geográficas relacionadas con el clima regional/urbano, así como en la producción de material de apoyo para la elaboración de directrices/planes municipales. La aplicación de las ecuaciones proporcionadas no sólo identificó la mayor temperatura porcentaje superficiales a diferentes escalas espaciales sino también que la dota de personal del campo término en diferentes escalas texturas, permite un mejor uso de los recursos ofrecido por el software, integrada y coherente con el área analizada y a la vez haciendo un énfasis en la mejora de la resolución espacial de 30 metros desde el aspecto de uso de geotecnología en entornos urbanos, contribuye a la identificación, espacial y comprensión de la dinámica del clima de trabajo de microclimas locales y en consecuencia, la adopción de las directrices forestación planea para suavizar las temperaturas en estos ambientes y se puede aplicar en otros rangos y diferentes lugares.

BORDES Y MARTÍNEZ (2005), en su investigación *Viticultura de precisión: Predicción de cosecha a partir de variables del cultivo e índices de vegetación*, cuyo objetivo principal de investigación fue mejorar, la toma de decisiones, el diagnóstico y la eficiencia en el uso de insumos. Se basó en la utilización de tecnologías de tratamiento de variable para la aplicación de semillas, fertilizantes, agua de riego, plagicidas, etc. La población de estudio fueron 40 parcelas en la viña de Raimat de entre 1.5 y 25ha, la muestra estuvo conformada por tres parcelas Cabernet Sauvignon (de 4.5 y 25ha), Merlot (de

6, 15 y 17 ha) y Tempranillo (de 8,13 y 15ha) la técnica de muestreo que se utilizó fue el procedimiento geo estadístico “kriging”, empleó como instrumento de predicción de cosecha, el cual fue el la regresión multivariante. Entre los principales resultados se muestra una escasa variabilidad, para predecir la cosecha total, aunque no se acoplan de igual forma a la predicción de la cosecha de manera delimitada. Se concluyó que es posible elaborar modelos de predicción con una elevada correlación cuando participan no solamente variables determinantes de la fertilidad si no también indicadoras del vigor del cultivo.

BUSTAMANTE (2003), en su investigación *Cartografía predictiva de variables climáticas: comparación de distintos modelos de interpolación de la temperatura en España Peninsular*, cuyo objetivo de investigación fue estimar la temperatura en puntos específicos basándose en superficies de predilección procedentes de un modelo de mejora digital “kriging”. La población de estudio fue España y se trabajó en 584 estaciones meteorológicas. Dentro de los métodos empleados fueron la interpolación, con casi infinitas variantes. MALCZEWSKI, (1997), la regresión múltiple con predictores procedentes de un modelo digital de elevación, proceso que se fundamentan en seleccionar predictores de entre un grupo de variables espaciales y topográficas, y el consecutivo ajuste de los coeficientes en un modelo de regresión lineal no paramétrico, mientras que el Kriging es un prototipo de interpolación espacial perteneciente a la geoestadística, que se fundamenta en aquellas variables que se modifican de forma continua en el espacio, los siguientes puntos espacialmente se inclinan a tener valores más semejantes a los que están más distanciados. Puesto que la mayor consecuencia en la temperatura del aire evaluada en ciertos lugares es el atribuible a la altitud, se enmendaron preliminarmente los valores de temperatura mediante regresión lineal, utilizando como instrumento de predicción la altitud nominal de la estación. A lo que se llegó a concluir fue que las regresiones polinómicas se inclinan a conductas erráticas en los límites del intervalo de interpolación y probablemente por esta causa se aprecian valores distantes de la realidad para determinadas estaciones de control (Hastie *et al.*, 1990).

FERNÁNDEZ (2018), en su trabajo de investigación *Cálculo de temperatura de superficie a partir de imágenes NOAA, LANDSAT Y SENTINEL-3*, tuvo como objetivo principal explicar adecuadamente el concepto de temperatura de superficie. Se enfocó en el cálculo de la temperatura de superficie mediante el empleo de datos apartados por los satélites de observación de la Tierra. Para ellos se empleó como instrumentos de medición para estimar la temperatura de brillo como: El sensor AVHRR de NOAA que indica la temperatura de brillo en Kelvin para un determinado valor de radiancia, los sensores térmicos de LANDSAT que transforman los valores de la temperatura de brillo mediante la inversión de la ecuación de Planck y se utilizó productos de temperatura de SENTINEL dentro del programa Copernicus de la ESA, la cual nos realiza el cálculo de reflectividad, de emisividad superficial de cada cubierta. Como resultado principal se obtuvo que los cálculos de temperatura se consideran elementos clave de estudios de cambio climático global. Y las posibilidades que ofrecen los satélites de observación de la Tierra en esta dirección son enormes al permitir obtener detalle espacial, espectral y temporal. Se concluyó que la temperatura de la superficie es una de las variables más importantes en muchos casos de estudio del medio físico.

OCAMPO y RIVAS (2013), en su investigación de *Estimación de la radiación neta diaria a partir de modelos de regresión lineal múltiple*, cuyo objetivo de investigación es como alternativa de un modelo de estimación menos costosa y más precisa que los métodos convencionales involucrando variables e informaciones meteorológicas para la estimación de la radiación neta que suceden a nivel superficial, como por ejemplo la evapotranspiración. La población de estudio fue una zona de clima húmedo de la Pampa Argentina. La muestra estuvo conformada por la ecuación Rn FAO 56 PM que requiere de un conjunto de datos meteorológicos por lo tanto las variables escogidas fueron humedad relativa, radiación solar y temperaturas media, máxima y mínima ( $T_a$ ,  $T_{max}$ ,  $T_{min}$ ). Los principales resultados se dieron, tanto en variables independiente como en dependientes, se derivaron en 8 ecuaciones (Rn1 - Rn8) de estimación de la Radiación neta. Las ecuaciones que funcionan

deficientemente corresponden a aquellas que no tomaron en cuenta la humedad relativa. Se concluyó que este modelo de regresión lineal múltiple considera distintas variables.

SEGURA y ORTIZ (2017), en su investigación *Modelación de la evapotranspiración potencial mensual a partir de temperaturas mínimas-máximas y altitud*, cuyo objetivo de investigación fue relacionar las variables temperatura mínima ( $TN$ ), temperatura máxima ( $TX$ ) y mensuales, meses del año ( $ME$ ) y altitud ( $AL$ ), con resultados de evapotranspiración potencial ( $ETP$ ) obtenidos con el modelo de Samani y Hargreaves ( $HS$ ), a partir de regresiones lineales multivariadas y estimar la precisión de los modelos adquiridos respecto a la  $ETP$  de Penman ( $PN$ ) y ( $HS$ ). Se basó en relación de los resultados con las variables  $ME$ ,  $AL$ ,  $TN$  y  $TX$ , para producir dos modelos de regresión lineal múltiple, a fin de evaluar la  $ETP$  mensual, para cada mes ( $ETP_m$ ) y otro general ( $ETP_g$ ). La población de estudio se realizó en México, empleó como instrumentos un total de 81 estaciones meteorológicas pertenecientes al Servicio Meteorológico Nacional con un total de 12 estaciones meteorológicas y 10 observatorios diferentes a los que se utilizaron para la obtención de los modelos ( $ETP_g$  y  $ETP_m$ ). Dentro se generaron dos modelos de regresión lineal múltiple ( $MRLM$ ). El primer  $MRLM$  fue general e involucró a los 972 grupos de datos, con  $ETP_{HS}$  como variable dependiente y  $TX$ ,  $TN$  como variables independientes, que corresponden a la altitud de las estaciones meteorológicas seleccionadas y 81 grupos de  $ME$  que concierne a los meses del año para cada estación y el segundo modelo fue para cada mes e involucró las variables independientes  $TX$ ,  $TN$  y  $AL$  agrupadas por mes. Se concluyó que la metodología propuesta demostró que las variables  $TX$ ,  $TN$ ,  $AL$  y  $ME$  pueden emplearse en sencillos modelos lineales múltiples para estimar  $ETP$  mensual así mismo, la  $TN$  y la  $AL$  influyen en la  $ETP$  de forma distinta en los meses, el modelo  $ETP_m$  que estima valores de  $ETP$  para cada mes es un modelo asequible para México, sin considerar la radiación ni la latitud.

El análisis de la presente investigación se basó en las siguientes teorías:

#### Teledetección

La teledetección espacial permite tomar información en condiciones comparables para comprender los procesos que perjudican al medio ambiente como el calentamiento global de la tierra o los procesos de desertización. Debido a esta razón es necesario un sistema de información que englobe un gran terreno. Chuvieco (2008) menciona que existe la dificultad para establecer bases de datos globales, ya que es indispensable integrar información proveniente de diversas fuentes, que frecuentemente están compiladas con criterios. Es por ello que la teledetección nos ofrece una fuente homogénea (el mismo sensor) y exhaustiva (abarca todo el territorio), lo que hace posible su incorporación en estudios a nivel global.

#### Espectro electromagnético

En 1924 Broglie unifica la teoría electromagnética, la cual que proviene de la teoría corpuscular y ondulatoria. Estas constituciones de luz se han establecido de acuerdo a su longitud de onda electromagnética, en donde las ondas más largas tienen su longitud en kilómetros y se encuentran en un extremo conocido como radio, mientras que las más cortas al otro extremo, donde la longitud de onda es de una billonésima de metros y es conocida como Gamma.

#### Cuerpo negro

En 1862 Gustav Kirchhoff introdujo el nombre de cuerpo negro refiriéndose a la luz emitida por un cuerpo negro, más adelante esto le ayudaría a plantear la ley de Kirchhoff donde indica que todos estos cuerpos negros, a igual temperatura, tienen la misma repartición de energía; es decir, la emisividad de radiación de todos los cuerpos negros experimenta la misma variación al variar la temperatura. Existe una relación directamente proporcional, cuando aumenta el poder emisor, la temperatura también lo hace.



## Estructura vertical y la relación de la atmósfera

Para un pequeño tanto por ciento, la densidad del aire a nivel del mar es de  $1.25\text{kg/m}^3$ . En los 100km más bajos de la atmósfera, la altura va de rangos de entre 7 a 8km aproximadamente. Generando la siguiente ecuación:  $\ln\frac{P}{P_0} = -\frac{z}{H}$ , esta relación es aplicada para estimar la altura de los distintos niveles de presión en la atmósfera de la Tierra. Estas variaciones verticales de la presión y la densidad son mucho más grandes que las variaciones horizontales correspondientes al tiempo (Wallace y Hobbs 2006, p. 26). Por lo tanto, es útil definir una atmósfera estándar, que representa la estructura el promedio horizontal y temporal de la atmósfera como una función de solamente altura.

## Regresión lineal múltiple

En 1805 Legendre publicó la primera forma de regresión lineal documentada, aplicando el método de los mínimos cuadrados, ahora conocido como modelo de regresión lineal múltiple, en donde se incluyen infinitas variables para determinar el valor requerido  $\hat{y}$  de la variable dependiente y. Este valor se obtiene mediante una ecuación lineal de las variables explicativas, de la siguiente forma:

$$\hat{y} = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n$$

## Teoría de Planck

Para obtener la temperatura de superficie, la radiancia espectral a nivel del sensor, banda térmica, fue transformada a temperatura de brillo del satélite, aplicando la siguiente ecuación (Landsat Project Science Office, 2008):

$$T_B = \frac{K_2}{\ln\left(\frac{K_1}{L + 1}\right)}$$

TL: Temperatura de brillo en grados Kelvin, para una radiancia L;

K1: Constante de calibración 1

K2: Constante de calibración 2 en grados Kelvin (adimensional);  
radiancia espectral del sensor

### Satélites de imágenes Landsat 8

El satélite Landsat 8 orbita la Tierra en una órbita polar casi síncrona al sol. El satélite tiene un ciclo de repetición de 16 días con un tiempo de cruce ecuatorial. Los valores de Landsat 8 se adquieren en el sistema de referencia mundial, con una superposición de franjas (o superposición lateral) que varía desde 7% en la línea ecuatorial hasta un máximo de aproximadamente el 85% en las latitudes extremas. El tamaño de la escena es de 170km x 185 km. Las imágenes digitales Landsat 8, pueden ser obtenidas gratuitamente del portal de la United States Geological Survey, las cuales pueden representar las estaciones del año, capturadas en horarios similares y en condiciones meteorológicas estables. Mediante el procesamiento de las imágenes digitales en el software ArcGis 10.3. (Moreno, 2018, p. 325).

### III. METODOLOGÍA

#### 3.1. Tipo y diseño de investigación

La investigación no experimental es un estudio donde no se requiere la manipulación deliberada de variables y que solo es cuestión de observar los fenómenos para poder analizar. (Sampieri, 2014, p. 152). Los diseños de investigación transversal se encargan de recolectar datos en un tiempo determinado. (Sampieri, 2014, p. 151). En nuestra investigación, la cual tiene como área de estudio el distrito de Vilque en Puno, se aplicará el diseño no experimental transversal, ya que la investigación no tiene intención de manipular nuestra variable dependiente, es decir, la temperatura y tiene como finalidad la recolección de datos en un solo periodo de tiempo, analizando su incidencia durante el año 2018.

El presente trabajo de investigación es de tipo aplicada. De acuerdo con Tamayo (2004), a la investigación aplicada se le denomina también activa o dinámica, la cual busca confrontar la teoría con la realidad. Es el estudio y aplicación de la investigación en características concretas y circunstancias. Por su parte Sanca (2011) define una investigación aplicada como aquella que utiliza la experiencia del investigador y la aplica en estudios de campo. Este tipo de investigación está íntimamente relacionado con la investigación básica. La experimentación a realizar en esta investigación se basa en insertar la información obtenida de las estaciones y la data satelital en los modelos de regresión lineal y la ecuación de Planck para determinar el modelo apropiado para la predicción de la temperatura del aire ante los fenómenos naturales.

El nivel de investigación, en este caso es de nivel explicativo. El interés se enfoca en esclarecer porque ocurre un fenómeno y en qué circunstancias se manifiesta, o porque se relacionan dos o más variables (Hernández et al., 2006). Nuestra investigación es de nivel explicativo porque cuenta con dos variables una dependiente y otra independiente, la dependiente es el modelamiento de la temperatura, por otro lado, nuestra variable independiente es la data satelital.

### **3.2. Variables y operacionalización**

Variable dependiente: el modelamiento de la temperatura, cuyo objetivo consiste en describir completa y precisa de acuerdo a los requerimientos necesarios, realizar diseños de controladores. De acuerdo a Scenna (1999) se tiene que basar varias ecuaciones sistemáticas; sin embargo, no representan un modelo único, ya que se pueden realizar representaciones diferentes del mismo. Por ejemplo, la temperatura al no ser homogénea en un cuerpo y presentar gradientes que dan lugar a ecuaciones avanzadas, suponiendo semejanza en todo el sistema.

Variable independiente: según el MINAM (2019) la data satelital son todas aquellas fotografías aéreas e imágenes digitales satelitales que juegan un papel primordial en la elaboración de mapas, en la adquisición y visualización de datos en los sistemas de información geográfica, ya que proporcionan un efecto visual sólido y una base para la colección de información espacial; sabemos que la principal fuente de energía que llega a nuestro planeta es la emitida por el sol, un sensor satelital registra, en un rango de longitud de onda definido, que viene a ser la banda manifestándose mediante el espectro electromagnético, el cual transforma esta información capturada en una imagen. Según Chuvieco (1996) menciona que el proceso de dispersión es el resultado de múltiples interacciones múltiples entre aerosoles atmosféricos y la radiación incidente, produciendo diversos tipos de energía en diferentes direcciones, mientras que la absorción ocurre cuando la energía incidente de una partícula es transformada por lo general en calor, reflejando longitudes de onda mayores.

### **3.3. Población, muestra y muestreo**

#### **3.3.1. Población**

Según Chávez (2004), la población es un conjunto de elementos que poseen las mismas características de los cuales se analizan para la obtención de resultados en la investigación.

Para la presente investigación, los datos empleados fueron los de temperatura de las redes de estaciones de Lampa, Pampahuta, Juliaca, Illpa, Palca, Pucara, Arapa, Cabanillas, Taraco, Huancane, Capachica, Los Uros, Puno, Isla Taquile, Huaraya Moho, Soto, Rincón de la Cruz, llave, Laraqueri, Juli, Tahuaco-Yunguyo, Isla Suana, Mazo Cruz, Pizacoma, Capazo, Tisco, Bocatoma, Paucarani, Talabaya, Susapaya, Aricota, Cairani, Pampa Umalzo, Carumas, Calacoa, Quinistanillas, Omate, Ubinas, Las Salinas, El Frayle, Patahuasi, Pampa de Arrieros, Pillones, Imata, Crucero Alto y Porpera.

### **3.3.2. Muestra**

#### **A. Tamaño de la muestra**

La muestra es un grupo pequeño de la población (Chavez, 2004); es decir, que del total de estaciones a nivel nacional hemos seleccionado solo 46 estaciones, de las que trabajaremos con promedio mensuales durante el año 2018.

La muestra está constituida por 12 unidades muestrales, datos adquiridos de los promedios de temperatura mensuales en Vilque-Puno, 2018. Es conveniente recoger datos por lo menos diariamente porque probablemente ello permita mejorar la calidad de los datos y existirá la facilidad de obtener mayor número de datos. No obstante, la entrega de datos mensual es una alternativa posible cuando no pueda efectuarse la transmisión diaria. (OMM et al, 2011, p. 47)

#### **B. Técnica de muestreo**

La técnica de muestreo es no probabilística. Es no probabilística, ya que por conveniencia se ha delimitado nuestro trabajo a analizar las temperaturas solo del año 2018.

### **3.4. Técnicas e instrumentos de recolección de datos**

#### **Técnica de recolección de datos**

La técnica de recolección de datos empleada en nuestra investigación fue el análisis documental. Según García (2000), menciona que es un proceso

útil que reside en acoplar de manera organizada la información. En este caso descargamos los datos hidrometeorológicos de la página del SENAMHI, la cual aplicaremos en modelos matemáticos (RLM y Teoría de Planck).

### **Instrumento de recolección de datos**

Dentro de la página web del SENAMHI<sup>1</sup>, en el módulo de la Dirección de Redes de Observación y Datos en la base de datos llamada Datos Hidrometeorológicos a Nivel Nacional se encuentran registrados los datos de las temperaturas que dependiendo de la estación cuentan con un registro desde el 2004 hasta la actualidad; sin embargo, para el trabajo que venimos analizando tomamos solo la información del 2018.

#### **A. Validez del instrumento**

Como parte de este trabajo de investigación es importante que todos los instrumentos, datos, teorías, procedimientos sean evaluados por expertos y posteriormente obtener un carácter de validez, de tal manera que el concepto dado por ese término, de un sentido de credibilidad a los investigadores. (Hernández, Fernández y Baptista, 2014); sin embargo nuestros datos están sistematizados, ya que para nuestra investigación hemos recopilados de la base de datos del módulo de la Dirección de Redes de Observación y Datos se garantiza la validez y confiabilidad con los que la entidad ha trabajado.

#### **B. Confiabilidad del instrumento**

La medición de la variable de temperatura ya se encuentra en la base de datos de un ente técnico del gobierno peruano, SENAMHI, estos datos ya están sujetos a ciertos correctivos, el cual nos otorgó la credibilidad de que la recopilación de los datos se trabajó de manera óptima.

---

<sup>1</sup> <https://www.senamhi.gob.pe/?&p=estaciones>

### 3.5. Procedimientos

Los procedimientos de la recolección de datos se detallan en el “Protocolo para la Instalación y Operación de estaciones Meteorológicas, Agrometeorológicas e Hidrológicas” del SENAMHI, el cual a través de la Resolución Presidencial Ejecutiva N° 0174 SENAMHI-PREJ-OGOT/2013 fue aprobada, en él se detalla lo siguiente:

Entre las funciones del SENAMHI, está “Estandarizar los procedimientos para la instalación y operación de estaciones meteorológicas, agrometeorológicas, hidrológicas, tanto convencionales como automáticas, cuyos datos sean utilizados con un fin oficial” y “Emitir opinión técnica sobre la instalación, operación y generación de datos de estaciones meteorológicas, agrometeorológicas, hidrológicas, tanto convencionales como automáticas en el ámbito nacional”, entre otras funciones.

La clasificación de las estaciones de observación, de las cuales se utilizó la data de las estaciones meteorológicas sinópticas, en su subclasificación de estaciones de superficie (estas realizan la observación a nivel de la superficie del lugar), clasificadas como estaciones convencionales, habiendo también las estaciones automáticas y estaciones de altitud, de estas últimas no se obtuvo datos.

Las ubicaciones de las estaciones sinópticas deben cumplir los siguientes requerimientos:

- A) En lo posible las estaciones sinópticas deben distar entre sí no más de 150 km
- B) La altitud de una estación sinóptica se especifica en metros enteros, calculada con un altímetro de alta precisión
- C) El área de las estaciones sinópticas debe ser preferentemente no menor a 6 x 8 m.

Las observaciones meteorológicas sinópticas en superficie son: dirección del viento, nubosidad (cobertura), tipo de nubes, visibilidad, temperatura del aire (incluidas las temperaturas extremas), humedad del aire, presión atmosférica, cantidad de precipitación y fenómenos especiales; de todas estas observaciones, para el trabajo de investigación emplearemos la temperatura del aire.

La instalación de las estaciones debe realizarse según los planos de diseño y distribución del instrumento y con los materiales a usarse por cada tipo de estación, (...) estas estaciones deben ser georeferenciadas y contar con un código de identificación, establecido por el SENAMHI, la denominación de la estación debe estar asociado al lugar donde se ubica.

Estas estaciones, de la Red Nacional de Estaciones, de conformidad con las normas técnicas de la Organización Meteorológica Mundial, deben ser evaluadas periódicamente por personal calificado para tales funciones, a fin de salvaguardar la calidad de las observaciones y el correcto funcionamiento de los instrumentos.

Los horarios de observación, para las meteorológicas sinópticas, las horas de observación están referidas al Tiempo Universal Coordinado, UTC, siendo las horas fijas principales 0000, 0600, 1200 y 1800 UTC.

### **3.6. Método de análisis de datos**

En este trabajo de investigación se aplicará el modelo matemático de Regresión Lineal Múltiple, en el cual se empleará el dato de las temperaturas recogidas de la base de datos del SENAMHI, así como los valores de latitud, longitud y altitud de cada estación, transformadas a coordenadas Universal Transversal de Mercator, UTM, para la generación del modelado de la temperatura donde se ajustará una recta a los puntos observados, a fin de usarla para predecir el valor Y para un valor dado de X. La relación entre las variables en la inferencia de la estadística dan antecedentes y consecuentes y no meros datos descriptivos (Botasso, 2009), para lo cual, con la interpolación de estos inferiremos los valores posibles de temperatura para áreas que no cuentan con una estación meteorológica cercana y con la ayuda del manejo de datos satelitales a través de un análisis espacial y cálculos matemáticos del comportamiento físico de la luz solar en la superficie terrestre poder generar dicha información para esas zonas.

Asimismo, se realizará un análisis inferencial, pues por medio de la inducción del comportamiento de la población estadística que está conformada por los datos de temperatura registrada por cada estación meteorológica se mostrará un patrón en el medio geográfico en el que se encuentra. En el



estudio de la teoría de errores, el hombre estima medidas y desviaciones típicas para obtener una ecuación para ofrecer una descripción aceptable de la magnitud, considerando errores de variables aleatorias e independientes unos de otros (Pearson, 1965); estas estimaciones numéricas nos permitirán concluir y contrastar nuestras hipótesis estadísticamente.

### **3.7. Aspectos éticos**

Se utilizó la ecuación de Planck, para poder reducir considerablemente el margen de error de nuestro modelo y aumentar la veracidad de los resultados. La veracidad de los resultados es un factor muy importante, debido a que en las prácticas siempre existirá algún tipo de error, así sean los resultados muy similares a los de la teoría (Acevedo, 2013, p.108).

Se debe de respetar la propiedad intelectual, actuando de una forma responsable, ética y legal en el uso adecuado de la información aplicada para realizar cualquier tipo de trabajo académico. La propiedad intelectual es una disciplina regulada que protege las creaciones intelectuales provenientes de un gran esfuerzo y digno de un reconocimiento (Rengifo, 1997, p.46).

#### IV. RESULTADOS

**Tabla 1. Estaciones Meteorológicas**

Estación	Coordenadas Geográficas		
	Latitud	Longitud	Altitud
LAMPA	15° 40' 24.4"	70° 22' 19.6"	3892
PAMPAHUTA	15° 29' 7"	70° 40' 32.8"	4400
PALCA	15° 14' 9.12"	70° 35' 35.34"	4073
ILLPA	15° 41' 0"	70° 5' 0"	3827
PUCARA	15° 2' 44.2"	70° 21' 59.9"	3900
ARAPA	15° 8' 10.5"	70° 7' 5.6"	3830
HUANCANE	15° 12' 5.4"	69° 45' 12.8"	3890
CAPACHICA	15° 36' 22.9"	69° 49' 55.7"	3828
LOS UROS	15° 48' 57.5"	69° 56' 9.7"	3808
ISLA TAQUILE	15° 43' 13.7"	69° 41' 27.6"	3850
RINCON DE LA CRUZ	15° 59' 26.1"	69° 48' 39"	3935
LARAQUERI	16° 8' 9.3"	70° 2' 45.2"	3928
JULI	16° 12' 13.6"	69° 27' 35.7"	3812
ISLA SUANA	16° 19' 48.8"	68° 51' 3.4"	3830
MAZO CRUZ	16° 44' 20.4"	69° 42' 55.7"	4003
PIZACOMA	16° 54' 25.3"	69° 22' 6.8"	3930
CAPASO	17° 11' 15.8"	69° 44' 7.8"	4530
BOCATOMA	17° 34' 47.5"	69° 37' 34.6"	4260
PAUCARANI	17° 31' 30"	69° 46' 46"	4609
TALABAYA	17° 33' 33"	69° 59' 59"	3420
SUSAPAYA	17° 21' 3.6"	70° 8' 0"	3433
ARICOTA	17° 19' 32.2"	70° 14' 7.3"	2825
CAIRANI	17° 17' 17"	70° 20' 20"	3920
CARUMAS	16° 48' 47"	70° 41' 40"	2976
CALACOA	16° 44' 6"	70° 40' 58.08"	3260
QUINISTANILLAS	16° 46' 46"	70° 53' 52"	1590
OMATE	16° 40' 39"	70° 58' 57"	2080
LAS SALINAS	16° 19' 4"	71° 8' 53"	4378
EL FRAYLE	16° 9' 17.35"	71° 11' 20.77"	4131
PATAHUASI	16° 3' 19.5"	71° 24' 53.3"	4035
PILLONES	15° 58' 43"	71° 12' 48"	4455
IMATA	15° 50' 33.56"	71° 5' 26.22"	4475
PORPERA	15° 21' 0"	71° 19' 0"	4195
JULIACA	15° 28' 28"	70° 10' 10"	3820
CABANILLAS	15° 10' 10.5"	69° 58' 11.6"	3920
TARACO	15° 18' 42"	69° 58' 20.9"	3849
PUNO	15° 49' 34.5"	70° 0' 43.5"	3812
HUARAYA MOHO	15° 23' 17.8"	69° 29' 3.4"	3890
ISLA SOTO	15° 33' 44.2"	69° 29' 19.8"	3815
ILAVE	16° 4' 3"	69° 39' 43"	3871
TAHUACO YUNGUYO	16° 18' 28.2"	69° 4' 29"	3891
PAMPA UMALZO	16° 52' 30"	70° 25' 25"	4609
UBINAS	16° 22' 19.4"	70° 51' 14.2"	3380
PAMPA DE ARRIEROS	16° 3' 47"	71° 35' 20"	3715
CRUCERO ALTO	15° 45' 52.06"	70° 54' 44.7"	4521
TISCO	15° 21' 0"	71° 27' 0"	4175

**Tabla 2. Resultados del modelado por Banda 10**

MODELADO DE LA ECUACIÓN DE PLANCK_BANDA 10												
ESTACIÓN	tsb10ene	tsb10feb	tsb10mar	tsb10abr	tsb10may	tsb10jun	tsb10jul	tsb10ago	tsb10sep	tsb10oct	tsb10nov	tsb10dic
LAMPA	-	-	15.90950	17.85840	14.61860	13.29880	13.54800	-	24.44910	-	-	30.51470
PAMPAHUTA	-7.69965	-	-5.19950	21.20080	19.89220	16.91840	16.81770	-	26.79440	-	-	33.73760
PALCA	14.68740	-	10.74140	19.75450	19.10290	12.28730	21.44380	-	22.07140	-	-	36.49980
ILLPA	-	18.8984	-	-	-	-	-	26.31900	-	40.41440	36.99560	-
PUCARA	-	-	-	-	-	-	-	0.00000	-	0.00000	0.00000	-
ARAPA	-	-	-	-	-	-	-	23.92610	-	36.81810	35.64850	-
HUANCANE	-	19.2347	-	-	-	-	-	22.20790	-	35.01110	34.66270	-
CAPACHICA	-	19.4475	-	-	-	-	-	26.14530	-	36.58050	35.10850	-
LOS UROS	-	12.2685	-	-	-	-	-	10.77110	-	14.57570	15.61140	-
ISLA TAQUILE	-	13.1725	-	-	-	-	-	12.04930	-	16.47890	16.87720	-
RINCON DE LA CRUZ	-	0.0000	-	-	-	-	-	24.76320	-	35.99000	34.35040	-
LARAQUERI	-	12.1997	-	-	-	-	-	24.86840	-	40.00830	39.09990	-
JULI	-	16.5917	-	-	-	-	-	22.35430	-	32.20200	31.32810	-
ISLA SUANA	-	16.3649	-	-	-	-	-	15.26480	-	23.25270	21.72300	-
MAZO CRUZ	-	19.2298	-	-	-	-	-	27.33940	-	43.35930	43.37760	-
PIZACOMA	-	-	-	-	-	-	-	-	-	-	-	-
CAPAZO	-	-	-	-	-	-	-	-	-	-	-	-
BOCATOMA	-	-	-	-	-	-	-	-	-	-	-	-
PAUCARANI	-	-	-	-	-	-	-	-	-	-	-	-
TALABAYA	-	-	-	-	-	-	-	-	-	-	-	-
SUSAPAYA	-	-	-	-	-	-	-	-	-	-	-	-
ARICOTA	-	-	-	-	-	-	-	-	-	-	-	-
CAIRANI	-	-	-	-	-	-	-	-	-	-	-	-
CARUMAS	14.03270	-	19.90360	22.76710	19.90340	17.72720	17.83880	-	27.23920	-	-	31.73970
CALACOA	12.26390	-	18.42300	22.37840	21.10920	20.03140	15.48240	-	27.07680	-	-	28.68060
QUINISTANILLAS	24.90500	-	36.99390	33.44240	31.37090	28.52140	26.20820	-	39.43400	-	-	43.72930
OMATE	19.32240	-	24.04730	21.82670	21.20530	19.36690	18.31500	-	26.99130	-	-	28.90180
LAS SALINAS	20.34620	-	17.64840	19.75680	21.06470	19.18550	0.00000	-	34.74690	-	-	40.80870
EL FRAYLE	14.36810	-	23.36900	30.40950	27.24700	23.97020	24.35310	-	40.00020	-	-	44.90560
PATAHUASI	20.78370	-	30.09010	33.89150	28.22380	25.41880	25.01070	-	37.52110	-	-	42.80340
PILLONES	0.12836	-	17.90170	21.42400	23.48100	18.56170	22.64670	-	36.96350	-	-	39.48920
IMATA	18.14230	-	20.48140	21.59270	21.43120	17.48540	15.37520	-	33.17470	-	-	32.17040
PORPERA	-	-	18.79780	22.76700	19.30350	16.23020	18.77770	-	32.69110	-	-	39.78550

**Tabla 3. Resultados del modelado por Banda 11**

MODELADO DE LA ECUACIÓN DE PLANCK_BANDA 11												
ESTACIÓN	tsb11ene	tsb11feb	tsb11mar	tsb11abr	tsb11may	tsb11jun	tsb11julc	tsb11ago	tsb11sep	tsb11oct	tsb11nov	tsb11dic
LAMPA	-	-	14.819800	17.075100	14.651400	13.290100	13.411800	-	23.224000	-	-	28.474500
PAMPAHUTA	-9.661630	-	-4.168030	21.067200	18.300900	17.414600	16.985400	-	26.161500	-	-	31.254200
PALCA	13.221500	-	10.342400	19.140800	18.292100	12.008900	21.118500	-	19.741300	-	-	33.847500
ILLPA	-	17.214500	-	-	-	-	-	25.398300	-	38.655900	34.371600	-
PUCARA	-	-	-	-	-	-	-	-	-	-	-	-
ARAPA	-	-	-	-	-	-	-	22.838800	-	35.496900	33.526100	-
HUANCANE	-	17.854900	-	-	-	-	-	21.065400	-	33.395000	31.867600	-
CAPACHICA	-	17.643000	-	-	-	-	-	25.076400	-	34.759500	32.517000	-
LOS UROS	-	10.934300	-	-	-	-	-	10.183200	-	14.092600	14.550500	-
ISLA TAQUILE	-	12.402800	-	-	-	-	-	11.722100	-	16.241300	16.492600	-
RINCON DE LA CRUZ	-	0.000000	-	-	-	-	-	24.042200	-	34.262200	32.351700	-
LARAQUERI	-	11.090300	-	-	-	-	-	23.646200	-	38.345200	36.541100	-
JULI	-	15.784100	-	-	-	-	-	21.764200	-	31.737500	29.196300	-
ISLA SUANA	-	15.234800	-	-	-	-	-	14.777800	-	22.522100	20.361000	-
MAZO CRUZ	-	17.890300	-	-	-	-	-	26.457700	-	41.894900	40.376100	-
PIZACOMA	-	-	-	-	-	-	-	-	-	-	-	-
CAPAZO	-	-	-	-	-	-	-	-	-	-	-	-
BOCATOMA	-	-	-	-	-	-	-	-	-	-	-	-
PAUCARANI	-	-	-	-	-	-	-	-	-	-	-	-
TALABAYA	-	-	-	-	-	-	-	-	-	-	-	-
SUSAPAYA	-	-	-	-	-	-	-	-	-	-	-	-
ARICOTA	-	-	-	-	-	-	-	-	-	-	-	-
CAIRANI	-	-	-	-	-	-	-	-	-	-	-	-
CARUMAS	12.698200	-	19.111200	21.871300	19.501300	17.147200	17.657400	-	26.388500	-	-	29.761200
CALACOA	10.717000	-	17.749100	21.597300	20.401900	18.987200	14.520900	-	25.783900	-	-	26.974000
QUINISTANILLAS	22.079200	-	34.621700	31.072600	30.333300	26.793700	24.948600	-	38.013400	-	-	40.485400
OMATE	17.383300	-	23.150400	20.710800	20.498500	18.306900	17.451100	-	25.986800	-	-	27.063400
LAS SALINAS	18.811000	-	16.951200	19.026800	20.240300	18.029900	0.000000	-	32.752500	-	-	38.492100
EL FRAYLE	13.495600	-	22.542300	28.749600	26.294700	22.328800	22.778300	-	37.912200	-	-	42.569900
PATAHUASI	19.550500	-	29.307500	32.670500	27.936400	24.139200	24.024100	-	36.479800	-	-	41.458900
PILLONES	0.341432	-	17.155300	20.813700	22.442500	17.563900	21.834800	-	35.276100	-	-	37.724800
IMATA	16.624500	-	19.941500	20.999900	21.485200	16.829800	14.343500	-	31.462900	-	-	31.293900
PORPERA	-	-	17.801700	21.831200	18.891200	15.494800	17.919000	-	31.012000	-	-	37.614400

## Imágenes Satelitales

Imagen Satelital de Enero




Imagen Satelital de Abril




Imagen Satelital de Mayo




Imagen Satelital de Febrero



Imagen Satelital de Junio



Imagen Satelital de Marzo




Imagen Satelital de Julio




Imagen Satelital de Octubre



Imagen Satelital de Agosto




Imagen Satelital de Noviembre





Imagen Satelital de Setiembre



Imagen Satelital de Diciembre



## Análisis inferencial

### Técnica de inferencia estadística

Modelado por Regresión Lineal Múltiple

1. Seleccionar las Estaciones meteorológicas más adecuadas para la zona de estudio.

Estas estaciones pueden estar dentro y fuera de la zona de estudio, las que se encuentren fuera del área de estudio no tienen que estar muy lejanas para evitar representar datos imprecisos.

2. Teniendo la relación de las estaciones, en una hoja Excel se colocan sus coordenadas UTM en X, Y y Z.

De la misma manera se crean 3 campos más, uno donde se coloquen los valores mensuales de temperatura los otros dos son campos calculados en el hablaremos líneas adelante.

3. Método estadístico Regresión Lineal Múltiple.

En el Excel se activa el complemento “Análisis de Datos”, en el cual encontraremos el método estadístico de Regresión. Después de utilizarlo se muestra una hoja de resumen, apreciamos R cuadrado (correlación) y los coeficientes para cada una de las variables utilizadas.

4. Campos “Fórmula” y “Residual”

“Fórmula”, dado que el método estadístico tiene la forma:

$$Y = \beta_0 + \beta_1X_1 + \beta_2X_2 + \dots + \beta_nX_n$$

Donde  $\beta$  son los coeficientes (de la hoja de resumen) y X son las variables utilizadas.

Para Tmax se utilizaron 33 estaciones, en donde el “Residual”, este campo es una resta del campo de temperatura mensual de la estación y de la “Fórmula”.

5. Dado que las estaciones ya cuentan con coordenadas UTM, lo llevamos a un proyecto .mxd en ArcMap.

Agregamos el evento de la tabla en Excel, para luego exportarlo como un shape de puntos. Este Shape ya tendrá la información de la temperatura mensual y el Residual el cual nos servirá para la interpolación.

6. Al mismo proyecto .mxd agregamos las siguientes capas:

Dem, los raster de coordenadas en X e Y (malla de coordenadas) y Shapes de límite distrital.

Con la herramienta de “Raster Calculator”, calculamos la ecuación de la “Formula” (del Item 4) el cual generara un nuevo grid, el cual lleva por nombre f (variable trabajaba)(mes) ejem: fmax\_ene

7. Interpolación del “Residual”

Para este cálculo nos dirigimos al Arctoolbox en el cual encontramos la herramienta de IDW (herramienta de interpolación), tener en consideración que la interpolación de tomar un área mayor a la zona de estudio, realizado este cálculo tendremos un nuevo grid el cual lleva por nombre r (variable trabajada)\_(mes), ejem: rmax\_ene

8. Ecuación “Formula” + Interpolación

Puesto que en el Excel realizamos una sustracción con el residual, ahora tendremos que hacerlo al contrario una adición de fmax\_ene + rmax\_ene (con el apoyo de la herramienta de “Raster Calculator”).

9. Extrac by Mask

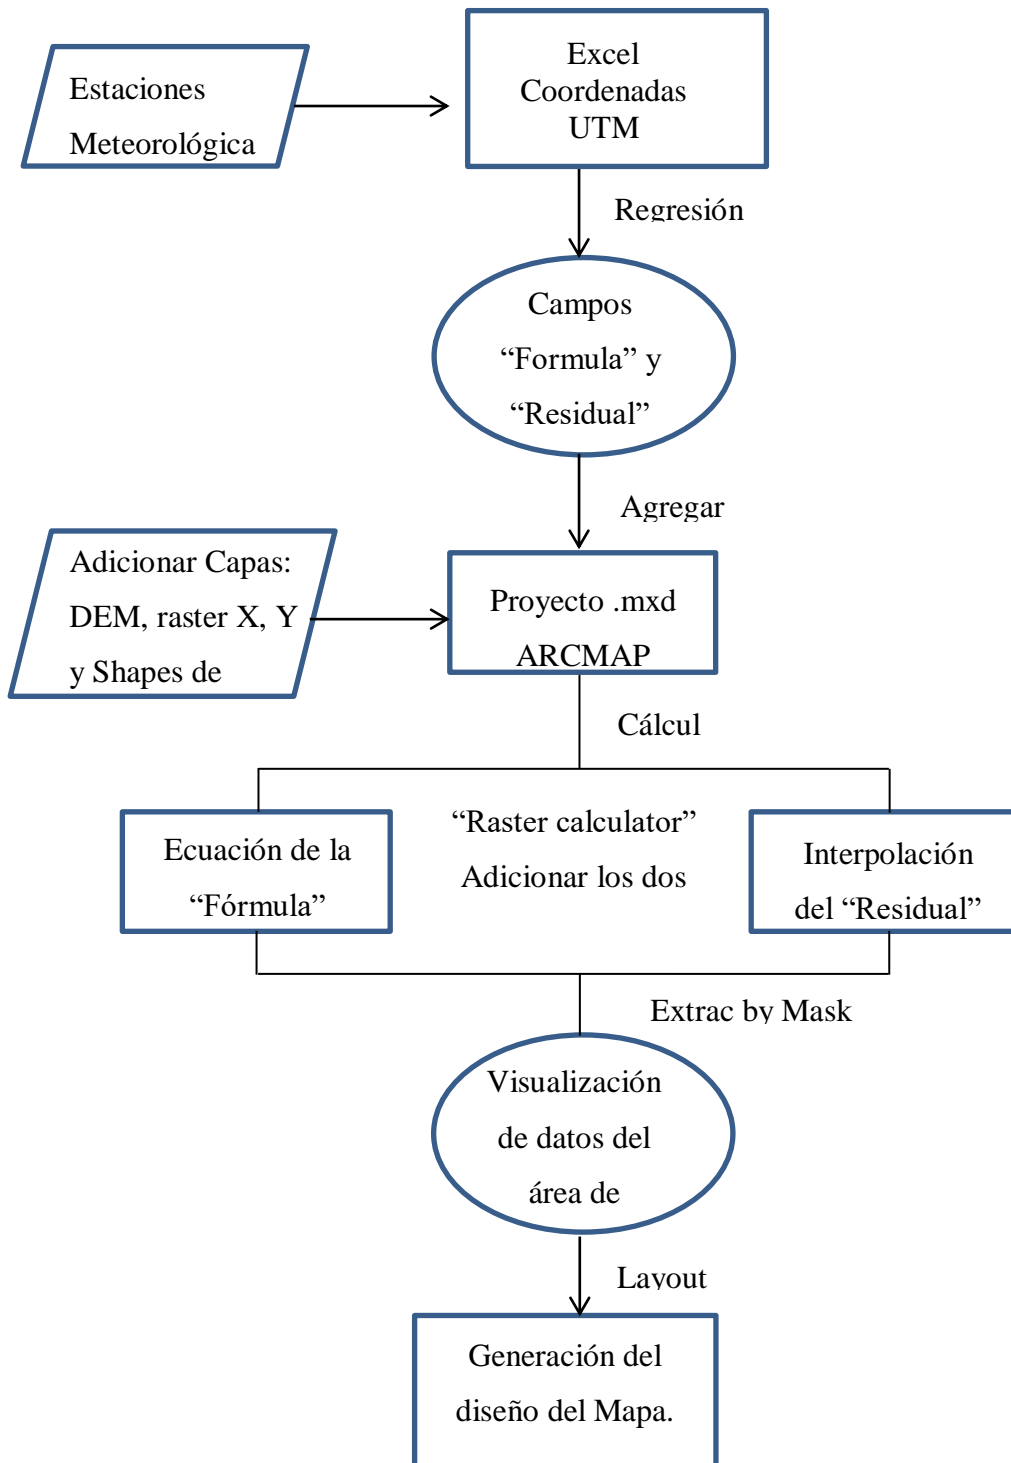
Con esta herramienta delimitamos nuestra zona de estudio, para que solo se visualice los datos del área que deseamos.



## 10. Salida de Mapa.

Con el comando de LAYOUT podremos generar nuestro mapa para luego exportarlo en formato .jpg u otro que se desee.

**Figura 1. Diagrama de generación de raster de temperatura**



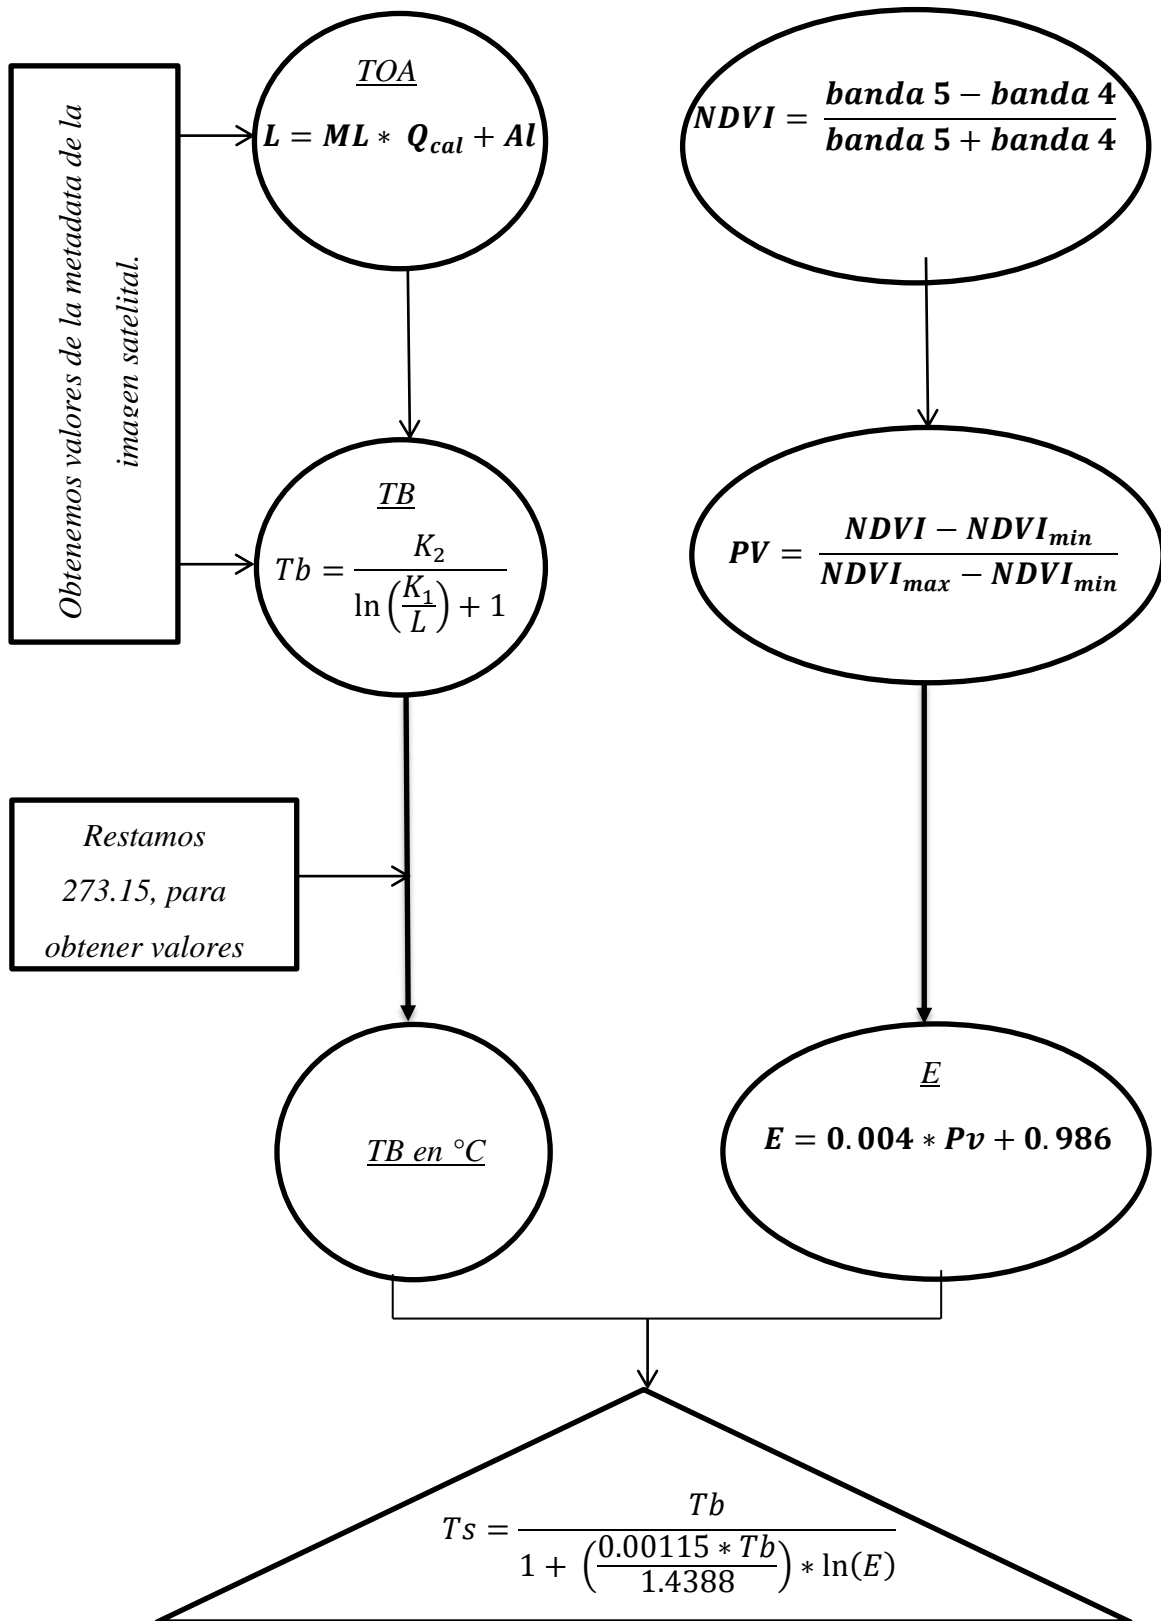
### **Modelado por la ecuación de Planck**

Para el cálculo de la temperatura de Brillo ( $T_b$ ), necesitamos realizar una corrección atmosférica (TOA), la cual nos servirá de entrada para el cálculo de  $T_b$ , la cual está manifestada por la siguiente fórmula:  $L = ML * Q_{cal} + AL$ ; realizado el cálculo se procede a reemplazar en la siguiente ecuación:  $T_b = K_2 / \ln[(K_1/L) + 1] - 273.15$

Para el cálculo de la Emisividad ( $E$ ), requerimos realizamos realizar algunas operaciones previas como el cálculo del índice de Vegetación de Diferencia Normalizada (NDVI), representada por la siguiente ecuación  $NDVI = (banda\ 5 - banda\ 4) / (banda\ 5 + banda\ 4)$ ; para luego extraer los valores mínimos y máximos que nos arroja dicho resultado, con lo cual emplearemos en el cálculo de Proporción de Vegetación (PV) con la ecuación siguiente  $PV = (NDVI - [NDVI_{min}]) / ([NDVI_{max}] - [NDVI_{min}])$ ; para que con ello por fin podamos emplear la emisividad, calculándola de la siguiente manera  $E = 0.004 * Pv + 0.986$ .

Por último, ya obtenido todos los datos requeridos para el cálculo de la Temperatura de Superficie de la Tierra, procedemos a emplear, como último cálculo, la ecuación que sigue  $T_s = T_b / (1 + ((0.00115 * T_b) / 1.4388) * \ln(E))$  para obtener valores de temperatura.

Figura 2. Diagrama de la Temperatura Superficial con imágenes satelitales



## Hipótesis general

Ho: La regresión lineal no es el modelo más apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018.

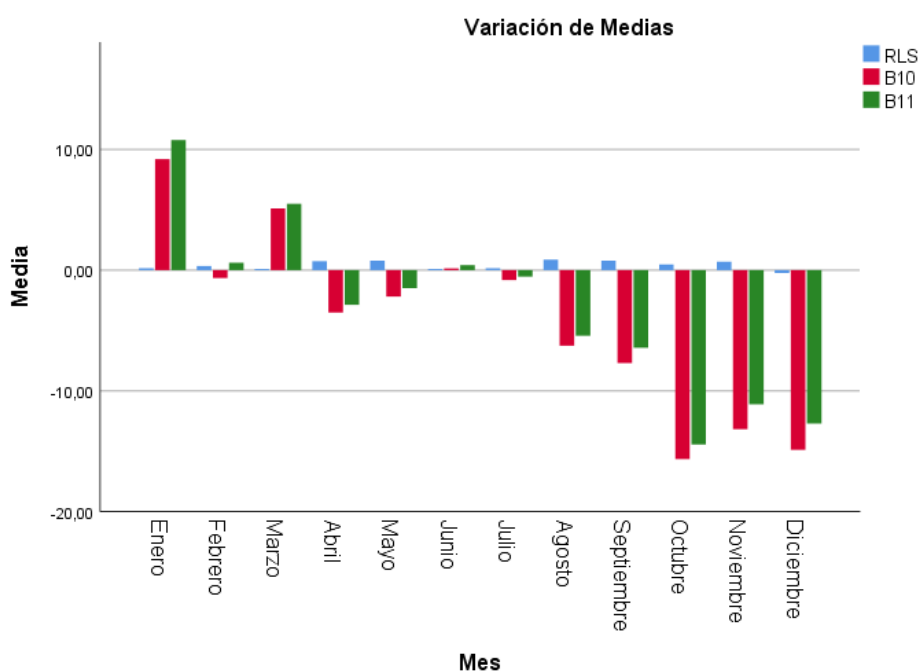
Ha: La regresión lineal si es el modelo más apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018.

**Tabla 4. Variación de medias de los modelos**

Mes	Variación de medias		
	RLS	B10	B11
<b>Enero</b>	1,597092750000000	9,199880250000001	10,777200250000000
<b>Febrero</b>	,350381555555555	-,648818444444444	,613259333333334
<b>Marzo</b>	1,110822400000000	5,114722400000001	5,499428400000001
<b>Abril</b>	,740400000000000	-3,511840000000000	-2,870340000000000
<b>Mayo</b>	,795460400000000	-2,182679600000001	-1,486939600000001
<b>Junio</b>	,111,345,199,999,990	,142025199999999	,425045199999999
<b>Julio</b>	,164605080000000	-,819129199999999	-,531789199999999
<b>Agosto</b>	,876118818181819	-6,257590272727271	-5,436090272727273
<b>Septiembre</b>	,788860000000001	-7,690179999999999	-6,423840000000000
<b>Octubre</b>	,482215000000000	-15,639357727272726	-14,431366818181818
<b>Noviembre</b>	,705033272727273	-13,168748545454546	-11,111357636363639
<b>Diciembre</b>	-,242135600000000	-14,876415600000000	-12,704215599999998

Como se aprecia en la tabla N° 4, para la variación de medias se escogió al modelo de regresión lineal simple como el adecuado para realizar la comparación de resultados con las estaciones meteorológicas, el cual muestra resultados más cercanos al valor cero. La variación de modelos se detalla en el anexo C.

**Figura 3. Barras de la variación de medias de los modelos**



Como se aprecia en la gráfica N° 3, las barras de color celeste son las más cercanas a cero (0), notándose que son los más cercanas a los valores obtenidos de las estaciones meteorológicas, lo que demuestra que la Regresión Lineal Simple es la que mejor modela la temperatura en Vilque – Puno 2018.

#### **A. Análisis de normalidad de los datos**

Se utilizará el estadístico de prueba de hipótesis de Kolmogorov - Smirnov debido a que el tamaño de la muestra es de 33 estaciones meteorológicas (empleadas en la modelación de la temperatura). Se tienen como hipótesis:

Ho: Los datos de temperatura tienen una distribución normal.

Ha: Los datos de temperatura tienen una distribución distinta a la normal.

**Tabla 5. Significancias de la normalidad**

<b>NORMALIDAD DE DATOS</b>	
<b>Mes</b>	<b>Sig.</b>
<b>Enero</b>	,000
<b>Febrero</b>	,000
<b>Marzo</b>	,000
<b>Abril</b>	,000
<b>Mayo</b>	,000
<b>Junio</b>	,000
<b>Julio</b>	,000
<b>Agosto</b>	,000
<b>Septiembre</b>	,000
<b>Octubre</b>	,000
<b>Noviembre</b>	,000
<b>Diciembre</b>	,000

Como se aprecia en la tabla N° 5, los valores de significancia son 0.000 por lo cual se rechaza la hipótesis nula (Los datos de temperatura tienen una distribución normal) y se acepta la alterna (Los datos de temperatura tienen una distribución distinta a la normal). La significancia de la normalidad se detalla en el anexo D.

Aunque nuestros datos no tienen una distribución normal, los datos de temperatura serán evaluados mediante el análisis estadístico de regresión lineal, para determinar si los residuos de estos muestran un patrón de linealidad o recta, con lo cual se podrá ajustar la dispersión de los datos de temperatura.

### **B. Prueba de hipótesis**

El estadístico empleado para la prueba de hipótesis en un primer momento fue la Regresión Lineal Múltiple, con la finalidad de evaluar la mayor cantidad de predictores de la temperatura en nuestro trabajo de investigación en los que se calculó los siguientes valores:

**Tabla 6. R cuadrados de la Regresión Lineal Múltiple**

<b>Regresión Lineal Múltiple</b>	
<b>Mes</b>	<b>R cuadrado</b>
<b>Enero</b>	,876
<b>Febrero</b>	,861
<b>Marzo</b>	,900
<b>Abril</b>	,861
<b>Mayo</b>	,897
<b>Junio</b>	,932
<b>Julio</b>	,928
<b>Agosto</b>	,942
<b>Septiembre</b>	,946
<b>Octubre</b>	,830
<b>Noviembre</b>	,718
<b>Diciembre</b>	,823

Como se aprecia en la tabla N° 6, los valores de R cuadrado son altos por lo que a pesar de que los datos de temperatura no tienen una distribución normal se presenta una fuerte relación entre ellos. Los R cuadrados de la Regresión Lineal Múltiple se detallan en el anexo E.

**Tabla 7. Coeficientes del modelo de Regresión Lineal Múltiple**

<b>Predictores</b>	<b>Significancias</b>											
	<b>Enero</b>	<b>Febrero</b>	<b>Marzo</b>	<b>Abril</b>	<b>Mayo</b>	<b>Junio</b>	<b>Julio</b>	<b>Agosto</b>	<b>Septiembre</b>	<b>Octubre</b>	<b>Noviembre</b>	<b>Diciembre</b>
<b>Constante</b>	,426	,458	,068	,067	,095	,892	,467	,275	,352	,061	,370	,170
<b>UTM X</b>	,357	,840	,651	,664	,802	,691	,328	,636	,697	,587	,816	,580
<b>UTM Y</b>	,592	,517	,739	,707	,892	,052	,017	,254	,458	,544	,944	,946
<b>Z</b>	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000

Como se aprecia en la tabla N° 7, las significancias en los coeficientes de la regresión línea múltiple fueron de ,000 solo para la variable Z (altitud) menores o iguales a 0.05 lo que nos indica que se rechaza la hipótesis nula y se acepta como variable predictora solo a la altitud. Por lo tanto se descarta como predictores a la constante, UTM X y UTM Y. La significancias se detallan en el anexo E.

Por lo que se volvió a trabajar con la Regresión Lineal Simple, dado que solo emplearemos una variable predictora que será la altitud (Valores Z).

**Tabla 8. R cuadrados de la Regresión Lineal Simple**

<b>Regresión Lineal Simple</b>	
<b>Mes</b>	<b>R cuadrado</b>
<b>Enero</b>	,871
<b>Febrero</b>	,859
<b>Marzo</b>	,899
<b>Abril</b>	,860
<b>Mayo</b>	,896
<b>Junio</b>	,922
<b>Julio</b>	,911
<b>Agosto</b>	,942
<b>Septiembre</b>	,887
<b>Octubre</b>	,827
<b>Noviembre</b>	,717
<b>Diciembre</b>	,821

Como se aprecia en la tabla N° 8, los valores de R cuadrado son altos por lo que a pesar de que los datos de temperatura no tienen una distribución normal se presenta una fuerte relación entre ellos, por tal razón se procedió a evaluar sus significancias. Los R cuadrados de la Regresión Lineal Múltiple se detallan en el anexo F.



**Tabla 9. Significancias de coeficientes de la Regresión Lineal Simple**

PREDICTORES	SIGNIFICANCIAS											
	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO	JULIO	AGOSTO	SEPTIEMBRE	OCTUBRE	NOVIEMBRE	DICIEMBRE
CONSTANTE	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000
Z	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000

Como se aprecia en la tabla N° 9, las significancias en los coeficientes de la regresión línea simple fueron de ,000 tanto para la constante como para la variable Z (altitud) menores o iguales a 0.05 lo que nos indica que se rechaza la hipótesis nula y se aceptan como variables predictores para el modelo final a la constante y a la variable Z. Las significancias se detallan en el anexo F.

**Tabla 10. Comparación de R cuadrados de los modelos de R.L.S y R.L.M.**

Mes	R cuadrado	
	Regresión Lineal Simple	Regresión Lineal Múltiple
Enero	,871	,876
Febrero	,859	,861
Marzo	,899	,900
Abril	,860	,861
Mayo	,896	,897
Junio	,922	,932
Julio	,911	,928
Agosto	,942	,942
Septiembre	,887	,946
Octubre	,827	,830
Noviembre	,717	,718
Diciembre	,821	,823

Como se aprecia en la tabla N° 10, los valores para R cuadrado en la regresión lineal simple son menores a los valores de R cuadrado en la

regresión lineal múltiple, pero para ésta última las significancias fueron mayores a 0.05 por lo que las variables predictoras no tenían relación, pero se observó que a mayor número de variables predictoras el R cuadrado tendía a mejorar.

**Tabla 11. Comparación de análisis ANOVA en los modelos de R.L.S y R.L.M.**

Mes	ANOVA RLM		ANOVA RLS	
	F	Sig.	F	Sig.
Enero	68,052	,000	210,059	,000
Febrero	60,013	,000	189,165	,000
Marzo	87,029	,000	274,688	,000
Abril	60,034	,000	190,435	,000
Mayo	83,908	,000	268,001	,000
Junio	131,886	,000	366,336	,000
Julio	123,902	,000	317,953	,000
Agosto	168,318	,000	503,713	,000
Septiembre	78,293	,000	242,489	,000
Octubre	47,223	,000	148,043	,000
Noviembre	24,570	,000	78,584	,000
Diciembre	44,809	,000	141,809	,000

Como se aprecia en la tabla N° 11, el valor de F obtenido para la regresión lineal simple fue mayor al valor F obtenido por la regresión lineal múltiple, cuya probabilidad asociada según las expectativas de la Hipótesis nula es menor del 0.0001 (valor de significancia), lo que nos lleva a rechazar tal hipótesis y suponer que existe un efecto real de dichas variables sobre el promedio de la temperatura en todos los meses.

Por lo tanto, se rechaza la hipótesis nula (la regresión lineal no es el modelo más apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018); y aceptamos la hipótesis alterna (la regresión lineal si es el modelo más apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018).

## Hipótesis específica 1

Ho: La banda 11 del infrarrojo térmico de la data satelital no es la ideal para el modelado de temperatura ante fenómenos naturales en Vilque - Puno, 2018

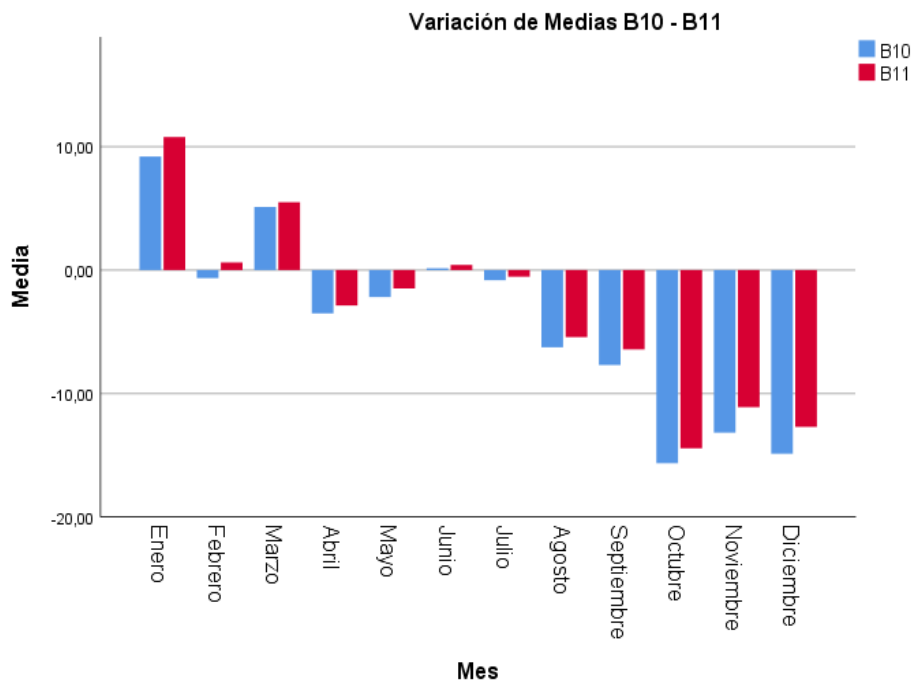
Ha: La banda 11 del infrarrojo térmico de la data satelital es la ideal para el modelado de temperatura ante fenómenos naturales en Vilque - Puno, 2018

**Tabla 12. Variación de medias de las Bandas**

Mes	Variación de medias	
	B10	B11
Enero	9.19988E+15	1.07772E+16
Febrero	-,6488184444444444	,6132593333333334
Marzo	5.11472E+15	5.49943E+15
Abril	3.51184E+15	2.87034E+15
Mayo	2.18268E+15	1.48694E+15
Junio	,1420251999999999	,4250451999999999
Julio	-,8191291999999999	-,5317891999999999
Agosto	6.25759E+15	5.43609E+15
Septiembre	7.69018E+15	6.42384E+15
Octubre	1.56394E+16	1.44314E+16
Noviembre	1.31687E+16	1.11114E+16
Diciembre	1.48764E+16	1.27042E+16

Como se aprecia en la tabla N° 12, los datos satelitales aplicados a la ecuación de Planck mostraron que la banda 11 se aproximan a los valores reales de las estaciones meteorológicas en los meses de febrero, abril, mayo, julio, agosto, septiembre, octubre, noviembre y diciembre; sin embargo, cabe resaltar que la banda 10 tiene resultados aceptables para los meses de enero, marzo y junio.

**Figura 4. Barras de la variación de medias de las Bandas**



Como se parecía en la gráfica 4, las barras de color rojo son en la mayoría de meses la que muestra mejores resultados, notándose que la banda 11 del infrarrojo térmico se adecua mejor en el modelo de la temperatura ante fenómenos naturales en Vilque - Puno, 2018

### **Hipótesis específica 2**

Ho: La emisividad óptima no se encuentra en el rango de 0.95 - 1 para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018.

Ha: La emisividad óptima no se encuentra en el rango de 0.95 - 1 para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018.

A través de la estimación de los valores medios de la emisividad se puede obtener el siguiente cuadro

**Tabla 13. Valores medios de Emisividad**

Emisividad	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
Vegetación	0.986	0.986	0.986	0.986	0.99	0.987	0.986	0.989	0.987	0.986	0.986	0.986
Suelo	0.988	0.988	0.992	0.99	1.1	0.999	1.12	1	0.996	0.99	0.988	1
Agua	0.992	0.992	0.995	0.996	1.19	1	1.21	1.01	1	0.998	0.992	1.013
Nieve	0.999	0.993	0.994	0.993	1.18	1	1.2	1.019	1.01	-	-	-

Como se aprecia en la tabla N° 13, se encontraron cuatro entidades de la cobertura terrestre que mostraron alta incidencia en los valores de Emisividad, siendo para los meses de octubre, noviembre y diciembre en la cobertura de nieve no se obtuvieron valores, toda vez que en las imágenes satelitales de los mismos meses no había presencia de esta cobertura; por lo tanto como indica en los antecedentes, se encontraron valores similares, siendo solo para los meses de mayo, junio y julio mayores a 1.

## V. DISCUSIÓN

Los resultados obtenidos mediante el presente trabajo de investigación, en el cual se utilizaron los modelos matemáticos de Regresión Lineal Múltiple, esta temática investigativa también ha sido abordada por Santana, Escobar y Capote (2010) en su trabajo, Estimación de un índice de calidad ambiental urbano, a partir de imágenes de satélite, en donde sus resultados fueron analizados con la correlación de Pearson (relación lineal entre dos variables cuantitativas aleatorias), considerando valores promedios de NDVI. De los indicadores de derivó un índice sintético de calidad ambiental que recoge el 95% de la varianza, y que responde de manera positiva a los efectos benéficos de la vegetación, y de manera negativa a los efectos adversos de la ciudad de cemento; Li & Weng manifiestan lo siguiente: “Los valores mayores a 0.71 se recomienda como excelente” (2005). El NDVI tiene correlación positiva ( $>0.98$ ) lo que denota la contribución benéfica de la vegetación y de su contenido de humedad en las hojas; lo cual se ve contrastada con nuestro trabajo donde a través de los cálculos realizados se obtuvieron valores promedios donde los rangos entre -1 a 0 son valores correspondientes agua o zonas con alta humedad, el rango de 0 a 0.3 represento valores a suelo o cobertura urbana y por último el rango de 0.3 a más resultaron ser áreas con presencia de cobertura vegetal; por lo que inferimos que los valores obtenidos tan bien quedarían explicadas con una correlación de Pearson toda vez que se elaboraron con la misma ecuación matemática, no obstante cabe resaltar lo siguiente, las imágenes utilizadas son de la misión Landsat, pero para el antecedente fue Landsat 7 o menor pues en él se explica que utilizaron el sensor de ETM+, mientras que para nuestro trabajo se empleó el sensor OLI de la misión Landsat 8, donde se tendría que evaluar una diferencia significativa entre una y otra.

Para el cálculo de la emisividad fue realizado gracias a que las imágenes Landsat 8 cuentan con las bandas roja e infrarroja para hallar el NDVI, así mismo Fernandez (2018) en su trabajo de Cálculo de temperatura de superficie a partir de imágenes NOAA, LANDSAT Y SENTINEL 3, trabajo con

las bandas 10 y 11 de landsat 8 donde se han estimado valores de emisividad medios, a los cuales ha de ser aplicada la misma corrección en función de la proporción de vegetación existente en cada pixel. Estimar la relación entre la emitancia de una superficie determinada y la que se produce en un cuerpo negro a la misma temperatura; en definitiva, es preciso conocer la emisividad de la cubierta para calcular la temperatura, obteniendo los siguientes datos: banda 10 (suelo: 0.9668; vegetación: 0.9863), banda 11 (suelo: 0.9747; vegetación: 0.9896); en nuestro trabajo presentado también calculamos valores de emisividad en los cuales hemos podido discernir 4 tipos de coberturas con mayor presencia dentro de la imagen satelital, las cuales son vegetación, suelo, agua y nieve, además se obtuvieron los valores promedios de 0.98675 para la vegetación, 0.9913 para el suelo, 1.0323 para el agua y de 1.0431 para la nieve; en donde podemos inferir que los valores obtenidos en nuestro cálculo se muestran un poco más altos a los promedios a los calculados el antecedente, además se encontró que los cuerpos de agua, en este trabajo ya se esté en estado líquido o sólido, tienen valores muy parecidos mostrándose algunas diferencias en las milésimas.

También para estimar valores en áreas con las que no se cuentan con información se utiliza las herramientas de interpolación en tal sentido Martínez y Bordes (2005) en su trabajo de Viticultura de precisión: Predicción de cosecha a partir de variables de cultivo e índices de vegetación, en donde a la imagen se corrigió radiométricamente dado que hay una relación entre una energía por la superficie emitida y la recibida en el sensor de donde se obtuvieron los valores de reflectancia espectral con los cuales se calculó el NDVI teniendo como resultado, que a un mayor crecimiento vegetativo no significa una mayor producción de uva y/o una mayor calidad, por otro lado obtuvieron una cobertura continua de cada variable muestreada aplicando un procedimiento geoestadístico como el kriging, en donde incorporaron otras variables del cultivo logrando mejorar la predicción espacial del rendimiento, llegando a valores del coeficiente de determinación de 0.65; para nuestro trabajo de investigación, también se realizó una corrección atmosférica para los valores de radiancia aplicando el método de TOA (Radiancia en el techo de la

atmosfera) la cual nos sirvió de insumo para los cálculos de la temperatura de brillo, por otro lado, en la aplicación de la geoestadístico empleamos el IDW (Inverse Distance Weighting) toda vez que se interpolan valores Z y para nuestro trabajo los valores tienen una relación entre la elevación del terreno – altitud y los valores de temperatura.

El periodo de la recolección de datos también es muy importante para obtener mejores modelos, Segura y Ortiz (2017) en su trabajo de Modelación de la evapotranspiración potencial mensual a partir de temperaturas máximas – mínimas y altitud. Analizan los datos observados que obtuvieron de la publicación de Datos Agroclimáticos para América Latina y el Caribe (FAO, 1985), que al estar reportados como promedio mensuales, se dividieron entre el número de días de cada mes, lo que sirvió para la verificación del desempeño de los modelos, los datos obtenidos fueron de 12 estaciones meteorológicas y 10 observatorios estos correspondían al periodo de 1951 a 2010 y los datos de los observatorios fueron del periodo de 1951 a 1980, con ellos se generaron modelos de regresión lineal múltiple para establecer la relación de un conjunto de variables independientes como temperatura máxima, mínima y la altitud y la dependiente de evapotranspiración potencial; con lo cual en nuestro trabajo, también recurrimos a datos observados que se encontraban en la página web del SENAMHI en la base de datos hidrometeorológicos, los cuales se encontraban para el periodo del 2018, de solo un año a diferencia del antecedente que tenía 60 y 30 años de datos registrados, con los cuales en un primer momento también aplicamos regresión lineal múltiple pero nuestros predictores no eran significativos salvo el valor de altitud, por lo cual se rehízo el modelo con regresión lineal simple o bivariada, con los cuales se obteniéndose mejores resultados.

Como se menciona en nuestro trabajo los valores de R cuadrado nos ayudan a evaluar el grado de error que puedan presentar por ello Ocampo (2013) en el trabajo de Estimación de la radiación neta diaria a partir de



modelos de regresión lineal múltiple, reconoce que el tipo de modelo aplicado fue predictivo ya que se esperaba, a partir del MRLM, estimar el valor de Y una vez conocidos los valores de Xi. Se partió de un modelo que incorpora la mayor cantidad de variables de entrada hasta llegar a una mínima cantidad, cubriendo las diferentes posibilidades de disponibilidad de datos de cada lugar, elaborando un resumen, dicho resumen considera el coeficiente de determinación múltiple ( $R^2$ ) y el error típico, siendo este último necesario para cuantificar el error en el pronóstico del valor de Y para cada valor de X. Sin embargo, hay que destacar que los modelos Rn5 y Rn6, que requieren menor cantidad de variables de entrada, presentan resultados semejantes al Rn1 (RMSE: 18 y 19  $W \cdot m^{-2}$ ); de la misma manera en nuestro trabajo de investigación, también se empezó a trabajar con MRLM pero al ser trabajados en el software estadístico de SPSS nos arrojaba valores de significancia mayores a 0.05, con lo que concluíamos que las variables predictoras no eran las adecuadas, en tal sentido, se evaluó con MRLS, observándose que los valores de R cuadrado eran menores en comparación del MRLM, con lo que inferimos que a mayor cantidad de predictores los modelos presentan un mayor ajuste de R cuadrado.

Todos nuestros resultados fueron trabajados dentro de la plataforma de sistemas de información geográfica, los cuales con programas como Arcgis son sencillos de graficar espacialmente, por ello Cárdenas *et al* (2013) en su trabajo Spatial technologies to evaluate vectorial samples quality in maps production, say what. Once the cartography was analyzed and referred to in the technologies used, we proceeded with some analysis of cuts made in ArcGIS, which in turn served as file elements and forms. Subsequently, a series of platform operators were used to begin with the integration of layers from the required information, after classifying the following layers of information that were integrated and their respective scales. Then, when an integration process is carried out, the combined data can include multi-temporal data, different spatial data resolutions, data from several sensors, data of various types of formats, etc. This randomly chosen object, described its position from UTM coordinates, which were analyzed with respect to the coordinates of the image,

used as a basis for the study area; Likewise for our research work the UTM coordinates were also used, but these were converted, since in the hydrometeorological database these coordinates were in geographic latitude, longitude and altitude; with them plus the temperature values the linear regression equations were elaborated for each month worked for the year 2018; said data data were also worked on geographic information systems (GIS) programs, such as the Arcgis, through the algebra map tool that could calculate the raster for the generation of temperature models in a spatial manner; Therefore, we infer that although mathematical calculations are performed in a timely manner, through the generation of a data matrix such as raster formats, values can be interpolated so that they can be visualized spatially.

## **VI. CONCLUSIONES**

De forma general se puede concluir, que la regresión lineal simple o bivariada es de la que mejor resultados se obtuvo al realizar modelado de la temperatura en la prevención de fenómenos naturales con el uso de datos satelitales con el algoritmo de Planck en Vilque - Puno, 2018, a comparación de la regresión lineal múltiple y el modelado con las imágenes satelitales. Adicionalmente se concluye que:

Se logró determinar que la banda 11 del infrarrojo térmico de la data satelital es la banda ideal para el modelado de la temperatura en la prevención ante fenómenos naturales en Vilque - Puno, 2018, toda vez que a comparación de la banda 10, los valores de esta primera fueron más cercanos a los medidos por la estaciones meteorológicas.

Se pudo identificar que la emisividad óptima para el suelo fue 0.991375 y para la vegetación 0.98675 en la data satelital para el modelado de la temperatura en la prevención ante fenómenos naturales en Vilque - Puno, 2018.

## VII. RECOMENDACIONES

La temperatura calculada mediante la ecuación de Planck es la que corresponde a la superficie, mientras que los valores de temperatura obtenidos de la base de datos hidrometeorológicos del SENAMHI, y según las normas de instalación de la caseta o garita meteorológica, estas están a una altura de 1.20 metros; aunque no se encontraron antecedentes que detallen esta circunstancia sería bueno determinar si existe alguna relación, incertidumbre o sesgo por esta diferencia de nivel vertical en el registro de los datos.

Las imágenes Landsat 8 utilizadas presentaban ruido dado que en algunos meses estas tenían una gran cantidad de nubes lo que dificultaba su procesamiento, por ello se recomienda que para trabajos futuros se trabaje con imágenes satelitales de mejor calidad y con poca o nula presencia de ruido, lo que facilitara el trabajo en los cálculos que se realiza para determinar cada uno de los ítem evaluados, como el NDVI, proporción vegetal, la temperatura de brillo, TOA, etc.

Los valores de emisividad obtenidos se podrían reclasificar y asignarse a todos los polígonos de la misma cobertura, toda vez que trabajar con una variedad de datos para una escena dificulta la selección de los rangos óptimos, pero cabe resaltar que se puede graficar en un histograma de los valores de emisividad y así poder clasificar por tipo de cobertura. Entre la literatura encontrada, en muchos trabajos se han podido determinar en una misma cobertura variedad de clases, por ejemplo para la cobertura de vegetación, pudieron identificar a los cultivos, zona de bosque, pastizales entre otros; lo cual se podría afinar la emisividad por tipo de clase.

## REFERENCIAS

ACEVEDO, I. Aspectos éticos en la investigación científica. *Cienc. enferm.* 2013, vol.8, n.1.

AGUILAR, H.; MORA, R. y VARGAS, C. Metodología para la corrección atmosférica de imágenes aster, rapideye, spot 2 y landsat 8 con el módulo flaash del software envi. *Revista Geográfica de América Central.* 2014, vol. 2, no 53, p. 39-59.

BBC News Mundo. Resumen 2018 del cambio climático. 2018.

Disponible en:

<https://elcomercio.pe/mundo/actualidad/resumen-2018-cambio-climatico-multimillonario-costos-10-peores-desastres-naturales-ano-2018-bbc-noticia-591997>

BOTASSO, O. El coeficiente de correlación, una historia de debates movilizantes. *Revista Médica de Rosario.* 2009, 75, 80-82.

BORDES, X. y MARTINEZ, J. Viticultura de precisión: Predicción de cosecha a partir de variables del cultivo e índices de vegetación. *Revista de teledetección.* 2005. 67-72pp.

Bustamante, J. Cartografía predictiva de variables climáticas: comparación de distintos modelos de interpolación de la temperatura en España Península. *Graellsia.* 2003.

CARDENAS, A.; TREVIÑO, E.; AGUIRRE, O.; JIMENEZ, J.; GONZALEZ, M. y NÉMIGA, X. Spatial technologies to evaluate vectorial samples quality in maps production. *Investigaciones Geográficas, Boletín del Instituto de Geografía, UNAM*. 2013, n.80 pp.111-128.

CHUVIECO, E. Teledetección ambiental, la observación de la tierra desde el espacio. 2008.

CORRAL, M. Caracterización de la estructura térmica de la atmósfera en la cuenca de Santiago y su relación con la calidad del aire. 2014.

DIAZ, O. Diseño de un proceso computacional basado en técnicas de minería de datos para el análisis del fenómeno del Niño. *Invest. Geog.* 2017, n68, pp. 40-53.

FERNÁNDEZ, A. Cálculo de temperatura de superficie a partir de imágenes NOAA, LANDSAT y SENTINEL-3. 2018.

GARCÍA, A. Introducción a la Metodología de la Investigación Científica. 2007.

HASTIE, T. y TIBSHIRANI, R. Generalized Additive Models: Monographs on Statistics and Applied Probability 43. 1990.

HERNÁNDEZ, S.; FERNÁNDEZ, C. y BAPTISTA, M. Metodología de la Investigación. 2014.

HERNÁNDEZ, S. Metodología de la investigación científica. 2006.

KUROIWA, J. Reducción de desastres: Viviendo en armonía con la naturaleza. 2002.

LANDSAT PROJECT SCIENCE OFFICE. Landsat 7 science data user's handbook, chapter II (Data products). 2008.

LI, G. y WENG, Q. Using Landsat ETM + imagery to measure population density in Indianapolis. Indiana. USA. *Photogrammetric Engineering and Remote Sensing*, 2005, 71, p.947-958.

MALCZEWSKI, J. Special Issue: Spatial Interpolation Comparison 97. *Journal of Geographic Information and Decision Analysis*. 1997, vol. 2, p.1-2

RENGIFO, E. Propiedad intelectual. El Moderno Derecho de Autor. 1996.

SANCA, M. Tipos de investigación científica. *Revista de Actualización Clínica Médica*. 2011, vol.9, pp. 621-624.

SÁNCHEZ, J. Metodología de investigación científica y tecnología. 2004.

SCENNA, N. Modelado, Simulación y Optimización de Procesos Químicos. 1999.

SEGURA, M. y ORTIZ, C. Modelación de la evapotranspiración potencial mensual a partir de temperaturas máximas-mínimas y altitud. *Tecnología y ciencias del agua*. 2017, vol. 8, n. 3, p. 93-110.

SENAMHI. Condiciones climáticas diciembre 2017 y perspectivas para el periodo enero - marzo 2018. 2018.

SENAMHI. Datos hidrometeorológicos a nivel nacional.

Disponible en: <https://www.senamhi.gob.pe/?p=estaciones>

Fecha de consulta: 28 de mayo de 2019

OCAMPO, D. y RIVAS, R. Estimación de la radiación neta diaria a partir de modelos de regresión lineal múltiple. *Revista Chapingo. Serie ciencias forestales y del ambiente*. 2013, vol. 19, no 2, p. 263-272.

Organización Meteorológica Mundial. Guía de Prácticas Meteorológicas. 2011.

PEARSON, K. Some incidents in the early history of biometry and statistics 1890-1894. *Biometrika*. 1965, 52, 3-18.

TAMAYO, M. El proceso de la investigación científica. 2004.

WALLACE, J. y HOBBS, P. Atmospheric Science: An Introductory Survey. *Elsevier*. 2006.



## ANEXOS

### Anexo A: Matriz de consistencia

Problemas de investigación	Objetivos de investigación	Hipótesis de investigación	Variables de estudio	Método
¿Cuál de los modelos es el mejor predictor de la temperatura ante fenómenos naturales en Vilque - Puno, 2018?	Determinar el modelo apropiado para la predicción de la temperatura ante fenómenos naturales en Vilque - Puno, 2018..	El uso de la data satelital mejorará en un 5% el modelado de la temperatura para la prevención ante fenómenos naturales en Vilque - Puno, 2018.	Modelado de temperatura	Regresión Lineal Múltiple
¿Qué banda de la data satelital es la ideal para el modelado de la temperatura ante fenómenos naturales en Vilque-Puno, 2018?	Determinar la banda de la data satelital ideal para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018	Las bandas del infrarrojo de la data satelital serán las ideales para mejorar el modelado de temperatura en la prevención ante fenómenos naturales en Vilque - Puno, 2018	Data satelital	Ecuación de Planck
¿Qué valores de la emisividad se obtienen en la data satelital para el modelado de la temperatura ante fenómenos naturales en Vilque-Puno, 2018?	Calcular los valores de la emisividad que se obtienen en la data satelital para el modelado de la temperatura ante fenómenos naturales en Vilque - Puno, 2018	La emisividad óptima se encuentra en el rango de 0.9668 - 0.9896 para mejorar el modelado de la temperatura en la prevención ante fenómenos naturales en Vilque - Puno, 2018.		

## Anexo B: Matriz de operacionalización de variables

<b>VARIABLES</b>	<b>Definición conceptual</b>	<b>Definición Operacional</b>	<b>Dimensiones</b>	<b>Indicadores</b>	<b>Escala de medición</b>
Modelado de la temperatura	Es el cálculo de la temperatura de superficie mediante el empleo de datos apartados por los satélites de observación de la Tierra (Fernández, 2018).	Seleccionar predictores de entre un grupo de variables espaciales y topográficas, y ajustarlos a los coeficientes en un modelo de regresión (Malczewski, 1997).	-	Temperatura (°C)	Intervalos
Data Satelital	Son imágenes digitales satelitales que permiten elaborar mapas para la visualización de datos en los sistemas de información geográfica (MINAM, 2019).	La temperatura de la superficie se obtiene con fórmulas en la banda del infrarrojo térmico del Sensor TIRS/Landsat-8 (Aguilar, Mora y Vargas; 2014).	Emisividad	-	Razón
			Banda	Longitud de onda (µm)	Intervalos

## Anexo C: Base de datos

Estación	Coordenadas Geográficas			Ubicación			Temperatura Promedio											
	Latitud	Longitud	Altitud	Departamento	Provincia	Distrito	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
LAMPA	15° 40' 24.4"	70° 22' 19.6"	3892	Puno	Lampa	Lampa	15.54	16.22	16.55	17.56	16.99	15.62	16.03	15.94	18.44	17.75	19.67	18.36
PAMPAHUTA	15° 29' 7"	70° 40' 32.8"	4400	Puno	Lampa	Paratia	14.36	15.38	13.54	13.76	11.53	11.40	11.09	12.82	12.98	12.06	12.00	11.83
PALCA	15° 14' 9.12"	70° 35' 35.34"	4073	Puno	Lampa	Vilavila	15.54	15.69	15.55	15.65	15.75	15.53	15.64	15.45	16.81	16.60	17.82	16.82
ILLPA	15° 41' 0"	70° 5' 0"	3827	Puno	Puno	Paucarcolla	17.35	18.59	16.95	16.98	15.73	15.70	15.65	15.93	15.99	15.71	15.75	15.91
PUCARA	15° 2' 44.2"	70° 21' 59.9"	3900	Puno	Lampa	Pucara	16.63	16.42	15.99	17.03	17.26	15.47	16.11	16.32	18.55	17.69	19.31	18.61
ARAPA	15° 8' 10.5"	70° 7' 5.6"	3830	Puno	Azángaro	Arapa	16.30	16.48	16.37	17.09	17.08	15.55	16.14	16.77	18.21	17.39	19.25	18.28
HUANCANE	15° 12' 5.4"	69° 45' 12.8"	3890	Puno	Huancane	Huancane	14.98	14.76	14.93	15.31	15.35	14.03	14.46	15.37	16.74	16.15	17.80	17.32
CAPACHICA	15° 36' 22.9"	69° 49' 55.7"	3828	Puno	Puno	Capachica	14.65	13.96	14.61	14.97	14.58	13.19	13.93	14.45	16.08	16.07	17.64	16.23
LOS UROS	15° 48' 57.5"	69° 56' 9.7"	3808	Puno	Puno	Puno	16.64	16.21	16.27	16.52	16.12	14.64	15.28	15.72	17.01	16.79	18.43	17.43
ISLA TAQUILE	15° 43' 13.7"	69° 41' 27.6"	3850	Puno	Puno	Capachica	16.11	15.81	15.76	16.34	14.90	14.07	14.38	14.80	16.54	16.83	18.95	17.78
RINCON DE LA CRUZ	15° 59' 26.1"	69° 48' 39"	3935	Puno	Puno	Acora	15.26	14.81	14.80	15.03	14.52	13.44	13.68	14.37	15.87	16.29	17.66	16.81
LARAQUERI	16° 8' 9.3"	70° 2' 45.2"	3928	Puno	Puno	Pichacani	16.01	15.91	16.00	16.28	15.88	15.83	15.82	15.62	16.82	16.62	18.53	17.09
JULI	16° 12' 13.6"	69° 27' 35.7"	3812	Puno	Chucuito	Juli	13.90	13.77	14.13	14.75	14.15	12.86	13.12	13.47	14.72	14.89	16.47	15.61
ISLA SUANA	16° 19' 48.8"	68° 51' 3.4"	3830	Puno	Yunguyo	Ollaraya	15.92	16.00	15.99	15.95	15.64	13.86	14.68	14.39	16.33	16.66	17.90	17.20
MAZO CRUZ	16° 44' 20.4"	69° 42' 55.7"	4003	Puno	El Collao	Santa Rosa	17.08	16.54	16.76	18.29	17.57	14.64	14.23	16.29	18.89	19.25	21.54	19.90
PIZACOMA	16° 54' 25.3"	69° 22' 6.8"	3930	Puno	Chucuito	Pizacoma	16.74	16.11	15.97	17.56	17.10	14.10	14.56	15.77	17.99	17.72	19.97	18.23
CAPASO	17° 11' 15.8"	69° 44' 7.8"	4530	Puno	El Collao	Capaso	13.41	13.58	13.67	14.00	12.77	10.20	9.91	11.69	14.02	15.39	16.85	14.88
BOCATOMA	17° 34' 47.5"	69° 37' 34.6"	4260	Tacna	Tacna	Palca	15.36	15.07	15.94	16.54	16.05	12.10	11.81	13.21	15.90	17.23	19.29	17.38
PAUCARANI	17° 31' 30"	69° 46' 46"	4609	Tacna	Tacna	Palca	12.31	11.71	13.00	13.64	11.78	8.09	8.85	9.80	12.77	14.56	15.70	14.45
TALABAYA	17° 33' 33"	69° 59' 59"	3420	Tacna	Tarata	Estique	16.85	17.60	17.34	17.49	17.56	16.40	16.25	17.69	18.59	18.31	18.52	18.57
SUSAPAYA	17° 21' 3.6"	70° 8' 0"	3433	Tacna	Tarata	Susapay	15.99	16.21	16.84	16.85	16.68	15.38	15.33	16.77	17.30	17.08	17.87	17.88
ARICOTA	17° 19' 32.2"	70° 14' 7.3"	2825	Tacna	Candarave	Quilahuani	18.01	18.33	18.81	18.52	19.21	18.39	18.33	19.54	19.76	19.10	19.09	19.63
CAIRANI	17° 17' 17"	70° 20' 20"	3920	Tacna	Candarave	Cairani	14.43	14.55	14.85	15.62	15.65	14.45	15.19	15.44	16.12	15.72	16.12	16.52
CARUMAS	16° 48' 47"	70° 41' 40"	2976	Moquegua	Mariscal Nieto	Carumas	20.17	19.33	19.79	20.42	20.21	19.34	19.15	20.37	21.32	20.40	21.39	20.35
CALACOA	16° 44' 6"	70° 40' 58.08"	3260	Moquegua	Mariscal Nieto	San Cristobal	20.02	20.00	19.93	19.01	19.23	19.08	19.14	19.40	19.63	19.22	19.48	19.43
QUINISTANILLAS	16° 46' 46"	70° 53' 52"	1590	Moquegua	Mariscal Nieto	Carumas	30.54	29.79	31.00	29.78	29.32	28.29	27.78	30.15	31.43	32.22	32.33	33.05
OMATE	16° 40' 39"	70° 58' 57"	2080	Moquegua	General Sánchez Cerro	Omate	25.08	24.20	25.56	25.01	25.27	24.60	24.32	26.40	26.96	26.82	27.27	27.05
LAS SALINAS	16° 19' 4"	71° 8' 53"	4378	Arequipa	Arequipa	Chiguata	11.72	12.48	12.41	13.68	12.56	10.39	10.94	11.95	13.61	13.95	15.19	14.87
EL FRAYLE	16° 9' 17.35"	71° 11' 20.77"	4131	Arequipa	Arequipa	San Juan de Tarucani	13.70	14.46	14.27	16.01	14.43	12.14	12.80	13.40	15.34	16.33	16.52	16.29
PATAHUASI	16° 3' 19.5"	71° 24' 53.3"	4035	Arequipa	Arequipa	Yura	14.72	15.45	15.08	16.94	15.70	13.09	14.04	14.94	17.00	17.69	18.52	18.67
PILLONES	15° 58' 43"	71° 12' 48"	4455	Arequipa	Caylloma	San Antonio de Chuca	12.05	11.99	11.70	13.47	12.06	10.52	9.63	11.43	13.58	14.45	15.70	14.89
IMATA	15° 50' 33.56"	71° 5' 26.22"	4475	Arequipa	Caylloma	San Antonio de Chuca	11.89	12.14	11.65	13.28	12.45	10.31	10.16	11.85	14.25	14.39	16.79	15.50
PORPERA	15° 21' 0"	71° 19' 0"	4195	Arequipa	Caylloma	Tisco	11.97	12.26	12.41	13.21	12.65	10.37	10.27	11.78	14.66	14.21	16.51	15.30
JULIACA	15° 28' 28"	70° 10' 10"	3820	Puno	San Román	Juliaca	16.67	16.26	16.94	17.79	17.68	15.81	15.86	17.00	18.98	18.67	20.76	-
CABANILLAS	15° 10' 10.5"	69° 58' 11.6"	3920	Puno	San Román	Cabanillas	16.72	16.00	16.64	17.22	17.45	15.69	16.03	16.78	19.12	18.68	20.36	18.79
TARACO	15° 18' 42"	69° 58' 20.9"	3849	Puno	Huancané	Taraco	15.78	15.03	15.52	15.93	16.49	14.93	15.39	16.24	17.39	16.88	18.96	-
PUNO	15° 49' 34.5"	70° 0' 43.5"	3812	Puno	Puno	Puno	15.04	14.41	14.27	14.74	14.51	13.21	13.55	14.16	15.93	15.72	17.19	15.30
HUARAYA MOHO	15° 23' 17.8"	69° 29' 3.4"	3890	Puno	Moho	Moho	14.99	14.82	14.79	15.46	14.96	13.51	13.96	15.01	16.67	15.64	17.71	-
ISLA SOTO	15° 33' 44.2"	69° 29' 19.8"	3815	Puno	Moho	Conima	-	15.79	16.10	15.74	16.02	15.94	15.75	15.54	15.89	15.91	16.18	15.92
ILAVE	16° 4' 3"	69° 39' 43"	3871	Puno	El Collao	Ilave	15.12	14.59	15.12	15.69	15.34	13.71	14.46	14.77	16.35	15.93	18.01	-
TAHUACO YUNGUYO	16° 18' 28.2"	69° 4' 29"	3891	Puno	Yunguyo	Yunguyo	13.95	14.42	14.33	15.14	14.40	12.22	13.19	13.23	15.26	14.94	16.72	-
PAMPA UMALZO	16° 52' 30"	70° 25' 25"	4609	Tacna	Candarave	Candarave	9.74	10.06	10.48	12.01	11.05	8.51	9.66	10.06	11.59	12.02	12.04	11.99
UBINAS	16° 22' 19.4"	70° 51' 14.2"	3380	Moquegua	General Sánchez Cerro	Ubinas	17.73	18.09	18.21	19.14	18.68	16.75	17.03	18.59	19.91	19.23	20.39	20.28
PAMPA DE ARRIEROS	16° 3' 47"	71° 35' 20"	3715	Arequipa	Arequipa	Yura	14.47	14.43	14.51	16.36	15.59	13.35	13.25	15.32	16.33	15.56	16.35	16.61
CRUCERO ALTO	15° 45' 52.06"	70° 54' 44.7"	4521	Puno	Lampa	Santa Lucía	11.79	11.43	11.35	12.75	11.99	9.55	-	-	-	14.73	16.41	14.63
TISCO	15° 21' 0"	71° 27' 0"	4175	Arequipa	Caylloma	Tisco	15.24	15.11	15.59	16.43	16.11	13.51	13.64	15.35	18.02	17.96	19.89	18.62



## Anexo E: Variación de medias

Enero

Informe					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Máximo	Mínimo
rlbfene	1,597092750000000	4	2,548660455306850	4,620555000000001	-1,208510000000000
tsb10ene	9,199880250000001	4	9,067137664777581	22,060940000000000	,848084000000000
tsb11ene	10,777200250000000	4	9,312910261209877	24,022920000000000	2,313984000000000
Total	7,191391083333334	12	8,085170370186063	24,022920000000000	-1,208510000000000

Febrero

Informe					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfeb	,850381555555555	9	1,554371190560279	-2,043757000000001	3,059514000000000
tsb10feb	-,648818444444444	9	3,501064612606254	-5,490357000000001	3,945786000000002
tsb11feb	,613259333333334	9	3,370064768040965	-3,685857000000000	5,279986000000001
Total	,271607481481482	27	2,908455060417187	-5,490357000000001	5,279986000000001

Marzo

Informe					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfmar	1,110822400000000	5	2,526499142768467	-2,111265000000000	4,451431999999999
tsb10mar	5,114722400000001	5	7,845467822122515	-,116503000000002	18,741435000000000
tsb11mar	5,499428400000001	5	7,030113298989484	,675896999999999	17,709965000000000
Total	3,908324400000000	15	6,144064223867464	-2,111265000000000	18,741435000000000

## Abril

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfabr	,7404000000000000	5	2,030832633918659	-2,5193330000000000	2,8884329999999999
tsb10abr	-3,5118400000000000	5	2,622348170893599	-7,4441330000000001	-,2984000000000001
tsb11abr	-2,8703400000000000	5	2,891367793707504	-7,3105330000000000	,4849000000000000
Total	-1,8805933333333334	15	3,047186598965410	-7,4441330000000001	2,8884329999999999

## Mayo

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfmay	,7954604000000000	5	3,035355671928793	-4,1198420000000000	3,7429059999999998
tsb10may	-2,1826796000000001	5	4,080572251480213	-8,3599419999999998	2,3749480000000000
tsb11may	-1,4869396000000001	5	3,485874232550609	-6,7686419999999998	2,3421480000000000
Total	-,9580529333333334	15	3,548986730891518	-8,3599419999999998	3,7429059999999998

## Junio

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfjun	1,8113451999999999	5	3,154276698042706	-2,6482740000000001	5,2186999999999998
tsb10jun	,1420251999999999	5	3,525820719814777	-5,5151739999999998	3,2426999999999999
tsb11jun	,4250451999999999	5	3,803842240342677	-6,0113740000000000	3,5210999999999999
Total	,7928051999999999	15	3,331465624380682	-6,0113740000000000	5,2186999999999998

## Julio

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfjul	1,6460508000000001	5	3,285707392126649	-3,1523330000000001	5,0810840000000002
tsb10jul	-,8191291999999999	5	4,594410572346109	-5,8083160000000000	3,6530840000000002
tsb11julc	-,5317891999999999	5	4,842638796302663	-5,8987329999999998	4,6145840000000003
Total	,0983774666666667	15	4,136886636719884	-5,8987329999999998	5,0810840000000002

## Agosto

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfago	,876118818181819	11	1,824288442100910	-1,2539060000000001	3,802541000000000
tsb10ago	-6,257590272727271	11	5,824668447055886	-11,693686999999999	4,945029000000000
tsb11ago	-5,436090272727273	11	5,631361622901554	-10,624787000000000	5,532929000000000
Total	-3,605853909090908	33	5,659160991942818	-11,693686999999999	5,532929000000000

## Septiembre

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfsep	,7888600000000001	5	2,760457946580423	-3,7630670000000001	3,0527670000000003
tsb10sep	-7,6901799999999999	5	3,513853289366105	-13,8110670000000000	- 5,2580670000000001
tsb11sep	-6,4238400000000000	5	3,950637249266124	-13,1781670000000000	- 2,9279669999999999
Total	-4,4417199999999999	15	5,010707155462676	-13,8110670000000000	3,0527670000000003

## Octubre

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfoct	,482215000000000	11	1,530947402355286	-1,2854969999999	2,979312999999998
tsb10oct	-15,639357727272726	11	9,684047046995394	-24,701497000000	2,217848000000002
tsb11oct	-14,431366818181818	11	9,183362971235255	-22,942997000000	2,700948000000002
Total	-9,862836515151518	33	10,574799874629392	-24,701497000000	2,979312999999998

## Noviembre

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfnov	,705033272727273	11	1,872532325990080	-2,5032999999999	3,936399999999999
tsb10nov	-13,168748545454546	11	9,100479894706833	-21,837600000002	2,815266999999999
tsb11nov	-11,111357636363639	11	8,340672230123989	-18,836100000002	3,876166999999999
Total	-7,858357636363636	33	9,341059257927878	-21,837600000002	3,936399999999999

## Diciembre

<b>Informe</b>					
RESIDUAL					
MÉTODO	Media	N	Desv. Desviación	Mínimo	Máximo
rlbfdic	-,242135600000000	5	3,210937784548044	-5,48639400000001	2,282032000000001
tsb10dic	-14,876415600000000	5	5,562516718156298	-21,911794000000	-9,251567999999999
tsb11dic	-12,704215599999998	5	5,197806663754270	-19,428394000000	-7,544968000000001
Total	-9,274255600000000	15	8,003194456175875	-21,911794000000	2,282032000000001



## Anexo F: Pruebas de Normalidad

Enero

Pruebas de normalidad						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,210	33	,000	,644	33	,000
a. Corrección de significación de Lilliefors						

Febrero

Pruebas de normalidad						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,336	33	,000	,865	33	,000
a. Corrección de significación de Lilliefors						

Marzo

Pruebas de normalidad						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,230	33	,000	,808	33	,000
a. Corrección de significación de Lilliefors						

Abril

Pruebas de normalidad						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,230	33	,000	,808	33	,000
a. Corrección de significación de Lilliefors						

Mayo

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,177	33	,004	,881	33	,001
a. Corrección de significación de Lilliefors						

Junio

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,277	33	,000	,604	33	,000
a. Corrección de significación de Lilliefors						

Julio

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,399	33	,000	,517	33	,000
a. Corrección de significación de Lilliefors						

Agosto

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,316	33	,000	,492	33	,000
a. Corrección de significación de Lilliefors						

Septiembre

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	Gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,265	33	,000	,761	33	,000
a. Corrección de significación de Lilliefors						

Octubre

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,238	33	,000	,813	33	,000
a. Corrección de significación de Lilliefors						

Noviembre

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,286	33	,000	,794	33	,000
a. Corrección de significación de Lilliefors						

Diciembre

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
TEMPERATURA	,223	33	,000	,789	33	,000
a. Corrección de significación de Lilliefors						

**Anexo G: Coeficientes del modelo de R.L.M. y R cuadrados de la R.L.M.**

Enero

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,936 <sup>a</sup>	,876	,863	1,380427441
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	T	Sig.
		B	Desv. Error	Beta		
1	(Constante)	20,145	24,964		,807	,426
	UTM_X18	3,477E-6	,000	,063	,935	,357
	UTM_Y18	1,601E-6	,000	,038	,542	,592
	Z	-,005	,000	-,950	-13,862	,000
a. Variable dependiente: TENE						

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	389,034	3	129,678	68,052	,000 <sup>b</sup>
	Residuo	55,262	29	1,906		
	Total	444,296	32			
a. Variable dependiente: TENE						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Febrero

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,928 <sup>a</sup>	,861	,847	1,382256952
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	T	Sig.
		B	Desv. Error	Beta		
1	(Constante)	18,823	24,997		,753	,458
	UTM_X18	7,575E-7	,000	,015	,203	,840
	UTM_Y18	1,942E-6	,000	,048	,657	,517
	Z	-,005	,000	-,940	-12,986	,000

a. Variable dependiente: TFEB

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	343,990	3	114,663	60,013	,000 <sup>b</sup>
	Residuo	55,408	29	1,911		
	Total	399,398	32			

a. Variable dependiente: TFEB

b. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Marzo

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,949 <sup>a</sup>	,900	,890	1,251706921

a. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	42,838	22,636		1,892	,068
	UTM_X18	1,541E-6	,000	,028	,457	,651
	UTM_Y18	-9,010E-7	,000	-,021	-,336	,739
	Z	-,005	,000	-,946	-15,398	,000

a. Variable dependiente: TMAR

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	409,064	3	136,355	87,029	,000 <sup>b</sup>
	Residuo	45,436	29	1,567		
	Total	454,501	32			
a. Variable dependiente: TMAR						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Abril

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,928 <sup>a</sup>	,861	,847	1,296735705
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	44,648	23,450		1,904	,067
	UTM_X18	-1,533E-6	,000	-,031	-,439	,664
	UTM_Y18	-1,053E-6	,000	-,028	-,380	,707
	Z	-,005	,000	-,917	-12,665	,000
a. Variable dependiente: TABR						

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	302,846	3	100,949	60,034	,000 <sup>b</sup>
	Residuo	48,764	29	1,682		
	Total	351,610	32			
a. Variable dependiente: TABR						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Mayo

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,947 <sup>a</sup>	,897	,886	1,227179806
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	38,340	22,192		1,728	,095
	UTM_X18	8,373E-7	,000	,016	,253	,802
	UTM_Y18	-3,580E-7	,000	-,009	-,136	,892
	Z	-,005	,000	-,947	-15,151	,000
a. Variable dependiente: TMAY						

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	379,087	3	126,362	83,908	,000 <sup>b</sup>
	Residuo	43,673	29	1,506		
	Total	422,760	32			
a. Variable dependiente: TMAY						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Junio

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,965 <sup>a</sup>	,932	,925	1,106274544
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	T	Sig.
		B	Desv. Error	Beta		
1	(Constante)	-2,738	20,006		-,137	,892
	UTM_X18	1,198E-6	,000	,020	,402	,691
	UTM_Y18	4,807E-6	,000	,104	2,031	,052
	Z	-,006	,000	-,988	-19,443	,000

a. Variable dependiente: TJUN

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	484,222	3	161,407	131,886	,000 <sup>b</sup>
	Residuo	35,491	29	1,224		
	Total	519,714	32			

a. Variable dependiente: TJUN

b. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Julio

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,963 <sup>a</sup>	,928	,920	1,111704583

a. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	-14,824	20,104		-,737	,467
	UTM_X18	2,980E-6	,000	,052	,995	,328
	UTM_Y18	6,032E-6	,000	,134	2,536	,017
	Z	-,006	,000	-,993	-18,989	,000

a. Variable dependiente: TJUL

b. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18



ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	459,385	3	153,128	123,902	,000 <sup>b</sup>
	Residuo	35,841	29	1,236		
	Total	495,226	32			
a. Variable dependiente: TJUL						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Agosto

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,972 <sup>a</sup>	,946	,940	,992101867
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	19,958	17,941		1,112	,275
	UTM_X18	-1,278E-6	,000	-,021	-,478	,636
	UTM_Y18	2,471E-6	,000	,053	1,164	,254
	Z	-,006	,000	-,981	-21,649	,000
a. Variable dependiente: TAGO						

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	497,010	3	165,670	168,318	,000 <sup>b</sup>
	Residuo	28,544	29	,984		
	Total	525,553	32			
a. Variable dependiente: TAGO						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Septiembre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,943 <sup>a</sup>	,890	,879	1,297399340

a. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	22,207	23,462		,946	,352
	UTM_X18	-1,374E-6	,000	-,025	-,393	,697
	UTM_Y18	2,088E-6	,000	,049	,752	,458
	Z	-,005	,000	-,950	-14,746	,000

a. Variable dependiente: TSEP

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	395,357	3	131,786	78,293	,000 <sup>b</sup>
	Residuo	48,814	29	1,683		
	Total	444,171	32			

a. Variable dependiente: TSEP  
b. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Octubre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,911 <sup>a</sup>	,830	,813	1,584807599

a. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	55,785	28,660		1,946	,061
	UTM_X18	-2,346E-6	,000	-,044	-,550	,587
	UTM_Y18	-2,082E-6	,000	-,050	-,614	,544
	Z	-,005	,000	-,892	-11,133	,000

a. Variable dependiente: TOCT

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	355,822	3	118,607	47,223	,000 <sup>b</sup>
	Residuo	72,837	29	2,512		
	Total	428,658	32			

a. Variable dependiente: TOCT

b. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Noviembre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,847 <sup>a</sup>	,718	,688	1,962735104

a. Predictores: (Constante), Z, UTM\_X18, UTM\_Y18

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	32,346	35,494		,911	,370
	UTM_X18	1,239E-6	,000	,024	,234	,816
	UTM_Y18	2,951E-7	,000	,007	,070	,944
	Z	-,005	,001	-,852	-8,244	,000

a. Variable dependiente: TNOV

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	283,953	3	94,651	24,570	,000 <sup>b</sup>
	Residuo	111,718	29	3,852		
	Total	395,671	32			
a. Variable dependiente: TNOV						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

Diciembre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,907 <sup>a</sup>	,823	,804	1,641122478
a. Predictores: (Constante), Z, UTM_X18, UTM_Y18				

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	41,732	29,678		1,406	,170
	UTM_X18	-2,472E-6	,000	-,045	-,559	,580
	UTM_Y18	-2,408E-7	,000	-,006	-,069	,946
	Z	-,005	,000	-,899	-10,978	,000
a. Variable dependiente: TDIC						

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	362,051	3	120,684	44,809	,000 <sup>b</sup>
	Residuo	78,105	29	2,693		
	Total	440,156	32			
a. Variable dependiente: TDIC						
b. Predictores: (Constante), Z, UTM_X18, UTM_Y18						

## Anexo H: R cuadrados de la R.L.S. y coeficientes de la R.L.S.

Enero

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,933 <sup>a</sup>	,871	,867	1,357607864
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	387,160	1	387,160	210,059	,000 <sup>b</sup>
	Residuo	57,136	31	1,843		
	Total	444,296	32			
a. Variable dependiente: TENE						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	36,391	1,420		25,628	,000
	Z	-,005	,000	-,933	-14,493	,000
a. Variable dependiente: TENE						

Febrero

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,927 <sup>a</sup>	,859	,855	1,346881135
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática		Sig.
1	Regresión	343,161	1	343,161	189,165	,000 <sup>b</sup>
	Residuo	56,237	31	1,814		
	Total	399,398	32			

a. Variable dependiente: TFEB

b. Predictores: (Constante), Z

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	35,221	1,409		25,001	,000
	Z	-,005	,000	-,927	-13,754	,000

a. Variable dependiente: TFEB

Marzo

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,948 <sup>a</sup>	,899	,895	1,219348552

a. Predictores: (Constante), Z

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	408,409	1	408,409	274,688	,000 <sup>b</sup>
	Residuo	46,091	31	1,487		
	Total	454,501	32			

a. Variable dependiente: TMAR

b. Predictores: (Constante), Z

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	37,038	1,275		29,041	,000
	Z	-,005	,000	-,948	-16,574	,000

a. Variable dependiente: TMAR

Abril

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,927 <sup>a</sup>	,860	,855	1,260107274
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	302,386	1	302,386	190,435	,000 <sup>b</sup>
	Residuo	49,224	31	1,588		
	Total	351,610	32			
a. Variable dependiente: TABR						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	34,677	1,318		26,310	,000
	Z	-,005	,000	-,927	-13,800	,000
a. Variable dependiente: TABR						

Mayo

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,947 <sup>a</sup>	,896	,893	1,189078514
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	378,929	1	378,929	268,001	,000 <sup>b</sup>
	Residuo	43,831	31	1,414		
	Total	422,760	32			
a. Variable dependiente: TMAY						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	36,251	1,244		29,147	,000
	Z	-,005	,000	-,947	-16,371	,000

a. Variable dependiente: TMAY

Junio

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,960 <sup>a</sup>	,922	,919	1,143676703

a. Predictores: (Constante), Z

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	479,166	1	479,166	366,336	,000 <sup>b</sup>
	Residuo	40,548	31	1,308		
	Total	519,714	32			

a. Variable dependiente: TJUN

b. Predictores: (Constante), Z

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	37,215	1,196		31,111	,000
	Z	-,006	,000	-,960	-19,140	,000

a. Variable dependiente: TJUN



Julio

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,955 <sup>a</sup>	,911	,908	1,191292385
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	451,231	1	451,231	317,953	,000 <sup>b</sup>
	Residuo	43,995	31	1,419		
	Total	495,226	32			
a. Variable dependiente: TJUL						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	36,717	1,246		29,467	,000
	Z	-,006	,000	-,955	-17,831	,000
a. Variable dependiente: TJUL						

Agosto

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,971 <sup>a</sup>	,942	,940	,991397935
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	495,084	1	495,084	503,713	,000 <sup>b</sup>
	Residuo	30,469	31	,983		
	Total	525,553	32			
a. Variable dependiente: TAGO						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	38,684	1,037		37,305	,000
	Z	-,006	,000	-,971	-22,444	,000

a. Variable dependiente: TAGO

Septiembre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,942 <sup>a</sup>	,887	,883	1,274397881

a. Predictores: (Constante), Z

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	393,824	1	393,824	242,489	,000 <sup>b</sup>
	Residuo	50,347	31	1,624		
	Total	444,171	32			

a. Variable dependiente: TSEP

b. Predictores: (Constante), Z

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	37,746	1,333		28,318	,000
	Z	-,005	,000	-,942	-15,572	,000

a. Variable dependiente: TSEP

Octubre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,909 <sup>a</sup>	,827	,821	1,547306940
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	354,440	1	354,440	148,043	,000 <sup>b</sup>
	Residuo	74,219	31	2,394		
	Total	428,658	32			
a. Variable dependiente: TOCT						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	36,736	1,618		22,699	,000
	Z	-,005	,000	-,909	-12,167	,000
a. Variable dependiente: TOCT						

Noviembre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,847 <sup>a</sup>	,717	,708	1,900170455
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	283,741	1	283,741	78,584	,000 <sup>b</sup>
	Residuo	111,930	31	3,611		
	Total	395,671	32			
a. Variable dependiente: TNOV						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	35,913	1,987		18,070	,000
	Z	-,005	,001	-,847	-8,865	,000
a. Variable dependiente: TNOV						

Diciembre

Resumen del modelo				
Modelo	R	R cuadrado	R cuadrado ajustado	Error estándar de la estimación
1	,906 <sup>a</sup>	,821	,815	1,595951555
a. Predictores: (Constante), Z				

ANOVA <sup>a</sup>						
Modelo		Suma de cuadrados	gl	Media cuadrática	F	Sig.
1	Regresión	361,197	1	361,197	141,809	,000 <sup>b</sup>
	Residuo	78,959	31	2,547		
	Total	440,156	32			
a. Variable dependiente: TDIC						
b. Predictores: (Constante), Z						

Coeficientes <sup>a</sup>						
Modelo		Coeficientes no estandarizados		Coeficientes estandarizados	t	Sig.
		B	Desv. Error	Beta		
1	(Constante)	37,423	1,669		22,419	,000
	Z	-,005	,000	-,906	-11,908	,000
a. Variable dependiente: TDIC						

### Anexo I: Ecuación de modelo de R.L.M.

REGRESIÓN LINEAL MÚLTIPLE	
Mes	Coefficientes
Enero	$Y=20.145+B1*3.477E^{-6}+B2*1.601E^{-6}+B3*-0.005$
Febrero	$Y=18.823+B1*7.575E^{-6}+B2*1.942E^{-6}+B3*-0.005$
Marzo	$Y=42.838+B1*1.541E^{-6}+B2*-9.0101E^{-7}+B3*-0.005$
Abril	$Y=44.648+B1*-1.533E^{-6}+B2*-1.053E^{-6}+B3*-0.005$
Mayo	$Y=28.340+B1*8.373E^{-7}+B2*-3.580E^{-7}+B3*-0.005$
Junio	$Y=-2.738+B1*1.198E^{-6}+B2*14.807E^{-6}+B3*-0.006$
Julio	$Y=-14.824+B1*2.980E^{-6}+B2*6.032E^{-6}+B3*-0.006$
Agosto	$Y=19.958+B1*-1.278E^{-6}+B2*2.471E^{-6}+B3*-0.006$
Septiembre	$Y=22.207+B1*-1.374E^{-6}+B2*2.088E^{-6}+B3*-0.005$
Octubre	$Y=55.785+B1*-2.346E^{-6}+B2*-2.082E^{-6}+B3*-0.005$
Noviembre	$Y=32.346+B1*1.239E^{-6}+B2*2.951E^{-7}+B3*-0.005$
Diciembre	$Y=41.732+B1*-2.472E^{-6}+B2*-2.408E^{-7}+B3*-0.005$

### Anexo J: Ecuación de modelo de R.L.S.

REGRESIÓN LINEAL SIMPLE	
Mes	Coefficientes
Enero	$Y = Bo X 36,391 -,005$
Febrero	$Y = Bo X 35,221 -,005$
Marzo	$Y = Bo X 37,038 -,005$
Abril	$Y = Bo X 34,677-,005$
Mayo	$Y = Bo X 36,251 -,005$
Junio	$Y = Bo X 37,215 -,006$
Julio	$Y = Bo X 36,717 -,006$
Agosto	$Y = Bo X 38,684 -,006$
Septiembre	$Y = Bo X 37,746 -,005$
Octubre	$Y = Bo X 36,736-,005$
Noviembre	$Y = Bo X 35,913 -,005$
Diciembre	$Y = Bo X 37,423 -,005$