

UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE CUENCA

CARRERA DE INGENIERÍA AMBIENTAL

TRABAJO DE TITULACIÓN PREVIO A LA
OBTENCIÓN DEL TÍTULO DE INGENIERO AMBIENTAL

Trabajo Experimental:

“VALORACIÓN DE LA CONCENTRACIÓN DE DIÓXIDO DE NITRÓGENO
ATMOSFÉRICO (NO_2) EN EL ÁREA URBANA DE LA CIUDAD DE CUENCA A
TRAVÉS DE IMÁGENES SATELITALES”

AUTOR:

CHRISTIAN PAUL CRIOLLO TENESACA

TUTOR:

Dr. FREDI LEONIDAS PORTILLA FARFAN, PhD

CUENCA – ECUADOR

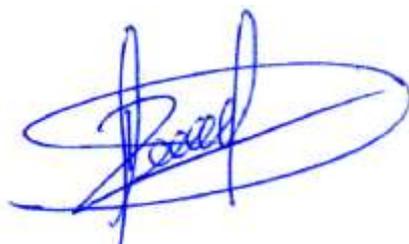
2018

CESIÓN DE DERECHOS DE AUTOR

Yo, Christian Paul Criollo Tenesaca con documento de identificación N° 0105684088, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de titulación: **“VALORACIÓN DE LA CONCENTRACIÓN DE DIÓXIDO DE NITRÓGENO ATMOSFÉRICO (NO_2) EN EL ÁREA URBANA DE LA CIUDAD DE CUENCA A TRAVÉS DE IMÁGENES SATELITALES”**, mismo que ha sido desarrollado para optar por el título de: *Ingeniero Ambiental*, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.

Cuenca, octubre de 2018



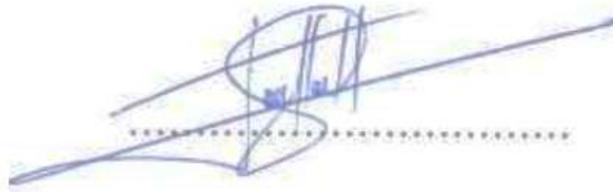
Christian Paul Criollo Tenesaca

0105684088

CERTIFICACIÓN

Yo, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: “**VALORACIÓN DE LA CONCENTRACIÓN DE DIÓXIDO DE NITRÓGENO ATMOSFÉRICO (NO_2) EN EL ÁREA URBANA DE LA CIUDAD DE CUENCA A TRAVÉS DE IMÁGENES SATELITALES**”, realizado por Christian Paul Criollo Tenesaca, obteniendo el *Trabajo Experimental*, que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana.

Cuenca, octubre de 2018

A handwritten signature in blue ink, appearing to be 'Fredy Portilla Farfán', written over a faint, dotted horizontal line.

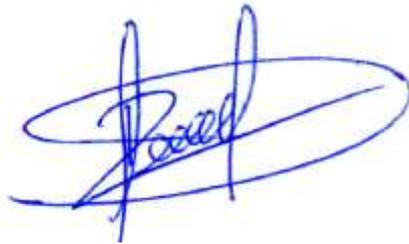
Fredi Portilla Farfán, PhD

0102824331

DECLARATORIA DE RESPONSABILIDAD

Yo Christian Paul Criollo Tenesaca, con cédula de identidad N° 0105684088, autor del trabajo de titulación: **“VALORACIÓN DE LA CONCENTRACIÓN DE DIÓXIDO DE NITRÓGENO ATMOSFÉRICO (NO_2) EN EL ÁREA URBANA DE LA CIUDAD DE CUENCA A TRAVÉS DE IMÁGENES SATELITALES”**, certifico que el total contenido de este *Trabajo Experimental* es de mi exclusiva responsabilidad y autoría.

Cuenca, octubre de 2018



Christian Paul Criollo Tenesaca

0105684088

DEDICATORIA

Este trabajo dedico en primer lugar a Dios por haberme permitido llegar hasta este momento importante en mi vida, a mis padres, Fredi y Elisabeth por el apoyo brindado e inculcarme su ejemplo que fue mi guía a seguir. De igual manera a mi hermano Freddy por ser mi mejor amigo y estar en todo momento. A mis Abuelos que han sido el pilar fundamental en nuestra familia quien con su esfuerzo me han transmitido su fortaleza para seguir adelante, a una persona muy importante y especial Martha, por su amistad sincera, comprensión y apoyo incondicional. A mis amigos y demás familiares que han estado presente durante esta etapa de vida.

AGRADECIMIENTOS

Agradezco al director de tesis Ing. Fredi Portilla, PhD por darme la oportunidad de realizar el trabajo de titulación además por la motivación y confianza.

Al Ing. Antonio Pérez por el apoyo brindado en la parte estadística y al Blgo. Danilo Mejía en la teledetección y sistemas de información geográficos.

A todos los docentes de la Universidad que aportaron con conocimientos y experiencias para mi formación académica.

RESUMEN

En las zonas urbanas ha aumentado la contaminación atmosférica, a causa de algunos factores como el incremento de vehículos de combustión interna, la presencia de industrias y el uso de combustibles fósiles, que generan dióxido de nitrógeno (NO₂). Por tal motivo la investigación se centra en valorar la concentración del contaminante atmosférico NO₂ a través de imágenes satelitales. La metodología aplicada se enfoca en relacionar los datos *in situ* de las concentraciones con los valores promedios espectrales de las imágenes satelitales Landsat 7 y 8 para obtener un modelo de regresión de mínimos cuadrados parciales (PLSR). Los resultados muestran que el modelo PLSR explica el 99,99 % y 77,78% de la variabilidad de las variables predictoras y de la variable explicativa (NO₂), respectivamente. Además en la validación se obtuvo un coeficiente de determinación ($R^2 = 0,78$) que nos expresan que son modelos aceptables. Finalmente se determinó que las mayores concentraciones se generaron en la parroquia de Totoracocha y Hermano Miguel. En conclusión el modelo puede ser aplicado para las decisiones de las autoridades municipales y ambientales.

Palabras clave: contaminación, dióxido de nitrógeno, Landast, regresión de mínimos cuadrados parciales.

ÍNDICE GENERAL

CESIÓN DE DERECHOS DE AUTOR	II
.....	II
CERTIFICACIÓN.....	III
DECLARATORIA DE RESPONSABILIDAD.....	IV
DEDICATORIA.....	V
AGRADECIMIENTOS.....	VI
RESUMEN.....	VII
ÍNDICE GENERAL	VIII
ÍNDICE DE TABLAS.....	XI
ÍNDICE DE FIGURAS.....	XII
ÍNDICE DE ANEXOS.....	XIII
CAPITULO 1. INTRODUCCION	1
1.1 Problema.....	1
1.2 Objetivos	3
1.2.1 Objetivo General.....	3
1.2.2 Objetivos Específicos	3
1.3 Fundamentación teórica.....	3
1.3.1 Teledetección	3
1.3.1.1 Elementos de la teledetección.....	4
1.3.1.2 Espectro electromagnético	6
1.3.2 Sensores.....	6
1.3.2.1 Sensores pasivos	6
1.3.3 Imágenes satelitales.....	7
1.3.3.1 Resolución de una imagen	7
1.3.4 Plataformas espaciales.....	8
1.3.4.1 Landsat 7.....	8
1.3.4.2 Landsat 8.....	9
1.3.4.3 Comparación de las bandas multiespectrales de las imágenes satelitales Landsat 7 y Landsat 8.....	10
1.3.5 Pre procesamiento de imágenes satelitales	11
1.3.5.1 Corrección radiométrica al Tope de la Atmósfera (TOA)	12
1.3.5.2 Método de Chávez de sustracciones de píxeles oscuros	12

1.3.6	Índices espectrales.....	13
1.3.6.1	Índice de vegetación normalizada (NDVI).....	13
1.3.6.2	Índice de vegetación mejorado (EVI).....	14
1.3.6.3	Índice de Diferencia de Agua Normalizada Modificado (MNDWI).....	14
1.3.6.4	Índice de vegetación ajustado al suelo (SAVI)	14
1.3.6.5	Índice de vegetación ajustado modificado (MSAVI)	14
1.3.6.6	Índice de estrés hídrico (MSI).....	15
1.3.6.7	Índice normalizado de áreas quemadas (NBR)	15
1.3.6.8	Índice de Diferencia Normalizada Edificada (NDBI)	16
1.3.7	Contaminación atmosférica	16
1.3.7.1	Dióxido de nitrógeno (NO ₂).....	17
1.3.7.2	Normativa	17
1.3.8	Regresión de Mínimos cuadrados parciales (PLSR).....	17
1.3.8.1	Coefficiente de determinación (R ²)	19
1.3.8.2	Raíz cuadrada del error cuadrático medio de predicción (RMSEP)	19
CAPITULO 2. MATERIALES Y MÉTODOS		20
2.1	Búsqueda de las imágenes satelitales Landsat.....	21
2.2	Imágenes satelitales válidas de la ciudad de Cuenca	22
2.3	Correcciones de las imágenes Landsat 7 y 8.....	22
2.3.1	Relleno de las imágenes satelitales Landsat 7.....	22
2.3.2	Corrección de reflectancia al tope de la atmósfera (TOA).....	23
2.3.3	Corrección atmosférica DOS1	23
2.4	Cálculo de los índices espectrales	24
2.5	Datos meteorológicos del cantón Cuenca.....	26
2.6	Red de calidad de aire de la ciudad de Cuenca	27
2.7	Extracciones de valores de las imágenes satelitales, índices espectrales y variables meteorológicas.....	28
2.8	Base de datos	28
2.9	Modelo de regresión y validación	28
2.9.1	Validación.....	29
2.10	Generación del mapa temático de la concentración de NO ₂	29
CAPITULO 3. RESULTADOS		30
3.1	Imágenes satelitales válidas.....	30
3.2	Pre procesamiento de las imágenes satelitales.....	31
3.2.1	Corrección de bandeo de Imágenes Landsat 7.....	31
3.2.2.	Corrección de reflectancia al tope de la atmósfera (TOA).....	32

3.2.3	Corrección atmosférica DOS1	33
3.3	Índices espectrales.....	34
3.4	VARIABLES meteorológicas.....	35
3.5	Estaciones de monitoreo de NO ₂	36
3.6	Modelo de Regresión de Mínimos Cuadrados Parciales (PLSR)	38
3.7	Validación	44
3.7.1	RMSEP.....	44
3.7.2	Coefficiente de determinación	45
3.8	Mapa de la concentración de dióxido de nitrógeno de la ciudad de Cuenca	47
3.9	Mapa de nivel de riesgo a la exposición de dióxido de nitrógeno	49
4.	DISCUSIÓN	50
5.	CONCLUSIONES.....	52
6.	RECOMENDACIONES.....	53
7.	BIBLIOGRAFÍA.....	54
8.	ANEXOS.....	61

ÍNDICE DE TABLAS

Tabla 1. Distribución de las bandas ETM+.....	8
Tabla 2. Distribución de las bandas en OLI y TIRS	9
Tabla 3. Rangos de longitud de onda (en micrómetros) para las bandas de reflectancia comunes a los sensores en Landsats 4, 5, 7 y 8.	11
Tabla 4. Puntos monitoreo de variables meteorológicas correspondiente al Cantón Cuenca	26
Tabla 5. Puntos de monitoreo pasivo NO ₂ en la ciudad de Cuenca	27
Tabla 6. Imágenes satelitales de Landsat 7 del periodo 2014-2016.....	30
Tabla 7. Imágenes satelitales de LANDSAT 8 del periodo 2014-2016.....	30
Tabla 8. Valores de reflectada TOA extraídos del periodo 2016.....	32
Tabla 9. Valores atmosféricos extraídos del periodo 2016	33
Tabla 10. Valores promedio de los Índices espectrales	34
Tabla 11. Valores promedio de las variables meteorológicas del periodo 2016 del Cantón Cuenca..	35
Tabla 12. Valores de variables meteorológicas del periodo 2016 de la ciudad de Cuenca.....	36
Tabla 13. Concentración de NO ₂ del periodo 2016	37
Tabla 14. Valores de las cargas de las variables del modelo PLSR de NO ₂	40
Tabla 15. Variancia explicada del modelo PLSR de NO ₂ según el número de componentes	42
Tabla 16. Coeficientes de regresión del modelo PLSR de dióxido de nitrógeno.....	43
Tabla 17. Comparación de valores reales vs predichos	48

ÍNDICE DE FIGURAS

Figura 1: Componentes de un sistema de teledetección.	5
Figura 2: Espectro Electromagnético.....	6
Figura 3. Metodología de investigación.....	20
Figura 4. Ubicación del área de estudio. Fuente: (Municipalidad de Cuenca , 2016)	21
Figura 5. Concentraciones de NO ₂ de las estaciones pasivas de monitoreo	38
Figura 6. Cargas de las variables predictoras del modelo PLSR	41
Figura 7. Residuos de 3 componentes del modelo PLSR	44
Figura 8. RMSEP del modelo PLSR en función a los 18 componentes	45
Figura 9. Coeficiente de determinación del modelo PLSR.....	46
Figura 10. Relación entre los valores medidos y predichos del NO ₂	46
Figura 11. Mapa de la concentración de NO ₂ de la ciudad de Cuenca aplicando el modelo PLSR	47
Figura 12. Mapa de riesgos de las concentraciones de NO ₂ de periodos largos	49

ÍNDICE DE ANEXOS

Anexo 1. Fórmulas utilizadas para la corrección atmosférica de Landsat 8	61
Anexo 2. Mapa de ubicación de las estaciones meteorológicas del cantón Cuenca.....	64
Anexo 3. Mapas de interpolación de humedad relativa, temperatura y precipitación mediante el modelo Kriging de la ciudad de Cuenca.	65
Anexo 4. Matriz multivariante.....	68

CAPITULO 1. INTRODUCCION

1.1 Problema

La contaminación atmosférica es uno de los principales inconvenientes en las áreas urbanas y rurales en el planeta, tanto en los países desarrollados al igual que países en desarrollo intermedio (Ministerio del Ambiente, 2010), el origen se debe que existe un aumento continuo de la población, la urbanización, el tráfico, la industrialización, el consumo y el uso de energía (González, Gómez , Rojas, Acevedo, & Aristizábal, 2017).

Una de las principales causas de contaminación se deriva de la cantidad de vehículos que aumenta a lo largo de los años. Ya que estos generan contaminantes como: dióxido de nitrógeno (NO₂), monóxido de carbono (CO), dióxido de carbono (CO₂), hidrocarburos y material particulado (MP), todos estos generan altos niveles de polución en los corredores urbanos citado por (Jaikumar , Nagendra , & Sivanandan, 2017), los mismos causan efectos sobre la salud, generando así la atención pública y científica a nivel mundial ya que la morbilidad por contaminación del aire es significativa (Cohen , Braver, Burnett, Anderson, & Frostad, 2017).

Cabe recalcar que en los estudios de (Gilbert, Goldberg , Brook, & Jerrett, 2007) documentan concentraciones elevadas de NO₂ atmosférico dentro de cientos de metros de carreteras debido a los vehículos de combustión interna.

En Ecuador los inconvenientes de carácter ambiental están ligados a la polución atmosférica y esto se muestran en las ciudades grandes, como Quito, Guayaquil y Cuenca, en el cual se observa un aumento de población urbana, crecimiento del parque automotor y las industrias presentes (Ministerio del Ambiente, 2010); (Mogrovejo, 2015).

Por lo cual la ciudad de Cuenca se unió a la Red Nacional de monitoreo de la calidad de Aire (ECUAIRE) en 1986 de forma irregular hasta 1988 (Cango & Carchipulla, 2010). En 1993, la Empresa Municipal de Teléfono, Agua Potable y Alcantarillado (ETAPA) de Cuenca

se hace cargo de la restitución de los aparatos de monitoreo, de su operación y mantenimiento (Municipalidad de Cuenca , 2008).

Actualmente, Cuenca tiene una red de monitoreo pasivo con 20 puntos de vigilancia distribuidos por la urbe, además consta de una estación automática que registra CO, SO₂, NO₂, O₃ y PM_{2,5} en tiempo real, que a su vez detalla las variables meteorológicas de temperatura ambiente (T), precipitación (PP) y humedad relativa (Municipalidad de Cuenca, 2011). En las estaciones de monitoreo pasivo se mide las concentraciones de (NO₂) dos veces por mes, de 10 a 12 días consecutivos (Municipalidad de Cuenca , 2016).

En el año 2016 fue donde se registró los mayores valores de NO₂ en dos estaciones, la primera con un valor de 42,7 µ/m³ y la segunda con 40,5 µ/m³, los mismo que sobrepasan los niveles de la Norma de Calidad Ambiental el mismo que da a conocer que el límite máximo permitido es de 40 µ/m³ (Municipalidad de Cuenca , 2016).

De acuerdo al último inventario de emisiones de la Ciudad de Cuenca realizado por la EMOV, establece que el factor más importante a tener en cuenta es el crecimiento del parque automotor ya que representa el 75% de la contaminación atmosférica, considerando que existe 110.00 vehículos privados y 475 buses urbanos (Diario El Tiempo, 2016).

Es por eso que surge la necesidad de realizar estudios para el monitoreo de contaminantes atmosféricos mediante el uso de sensores remotos dando óptimos resultados en la generación de modelos para determinar sus concentraciones (Hameed & Hasan, 2014), ya que permiten mapear y determinar las concentraciones de los diferentes contaminantes en el área urbana y poder estimar las zonas de mayor riesgo para la salud, además los datos satelitales se pueden usar para monitorear la contaminación del aire en áreas de difícil acceso (Saraswat, Mishra , & Kumar, 2017).

Varios estudios de contaminantes como el PM10 han demostrado relaciones entre los datos satelitales y el mapeo de contaminación atmosférica. Por lo cual las imágenes satelitales del sensor Landsat son utilizadas para aplicaciones de monitoreo multitemporal de contaminantes atmosféricos, además este método tiene una ventaja sobre otros ya que ofrece una amplia cobertura del área de estudio (Saraswat et al., 2017).

En la presente investigación se abordará el contaminante atmosférico, dióxido de nitrógeno para realizar el análisis y formulación de un modelo de regresión, que estime la concentración de NO₂, en el área urbana de la ciudad de Cuenca.

1.2 Objetivos

1.2.1 Objetivo General

- Valorar la concentración de Dióxido de Nitrógeno atmosférico (NO₂) en el área urbana de la ciudad de Cuenca a través de imágenes satelitales.

1.2.2 Objetivos Específicos

- Obtener las imágenes satelitales del repositorio digital y los datos *in situ* de la concentración de NO₂ de la Red de Monitoreo de Calidad del Aire de la ciudad de Cuenca del periodo 2014-2016.
- Identificar un modelo de regresión que estime la concentración de NO₂ en el área urbana de la ciudad de Cuenca.
- Generar un mapa para la identificación de las concentraciones de NO₂ en el área urbana de la ciudad de Cuenca.

1.3 Fundamentación teórica

1.3.1 Teledetección

En la actualidad la percepción remota o teledetección se ha convertido en uno de los instrumentos más relevantes en los distintos campos de la investigación, esto se debe a que nos

permite adquirir datos sobre las propiedades físicas de los objetos y los recursos naturales en función a muestreos y observaciones hechas desde una determinada distancia, dicho de otro modo, sin estar en contacto directo con ellos (Soria & Matar de Saquis , 2016); Por lo tanto, la teledetección es el proceso de inferir parámetros de la superficie desde de las mediciones de la radiación electromagnética (EMR) hasta la superficie terrestre (Kumar, 2013)

Si el origen de la energía es proveniente de la radiación solar, esta se, denomina teledetección pasiva, y el producto generado es una escena digital (Richards & Jia, 2006). En cambio si la energía no es proviene del Sol, sino que utiliza la plataforma de sensor, se establece como teledetección activa, esta puede ser los dispositivos de radar (Richards & Jia, 2006).

Los datos que serán recopilados pueden ser de muchas formas: variaciones en las distribuciones de ondas acústicas (sonar), variaciones en las distribuciones de fuerza (medidor de gravedad), variaciones en las distribuciones de energía electromagnética, etc. (Abdulrahman , 2010).

Los datos recolectados por varios sensores serán analizados para obtener información sobre los objetos o las características que se investigan.

1.3.1.1 Elementos de la teledetección

La percepción remota o teledetección es básicamente una ciencia multidisciplinaria que incluye una combinación de diversas disciplinas. Todas estas tecnologías están integradas para actuar como un sistema complejo en sí mismo, conocido como sistema de detección remota (Aggarwal, 2003).

Es por eso que el proceso implica una interrelación entre la radiación reflejada y los elementos a ser analizados, el mismo que necesita 7 componentes para una operación exitosa (Figura 1) los cuales se enunciarán a continuación (Abdulrahman , 2010).

- **Fuente de energía o iluminación:** El primer componente que se necesita es una fuente energética que prevea radiación electromagnética al cuerpo o elemento.
- **Radiación y la atmósfera:** A medida que la energía se desplaza desde el origen hasta el cuerpo o elemento, se interrelaciona con el ambiente por el que atraviesa.
- **Interacción con el cuerpo o elemento:** La energía emitida, alcanza el cuerpo o elemento mediante la atmósfera, e interactúa en función de sus características y la radiación.
- **Sistema sensor:** Una vez dispersada o emitida la energía a partir del cuerpo o elemento, se necesita un sensor para adquirir y registrar la radiación electromagnética.
- **Recepción y comercialización:** La energía que registro el sensor debe transmitirse para que se codifique y almacene la información con el fin de convertir la información a imágenes digitales (Instituto Nacional de Estadística y Geografía , 2014).
- **Interpretación y análisis:** la imagen procesada se interpreta, visual y/o digital o electrónicamente, con el objetivo de extraer información ya sea de fenómenos, objetivos e incluso análisis climáticos, etc. (Instituto Nacional de Estadística y Geografía , 2014).
- **Aplicación:** finalmente se aplica los datos extraídos de las imágenes sobre el objetivo para comprenderlo mejor.

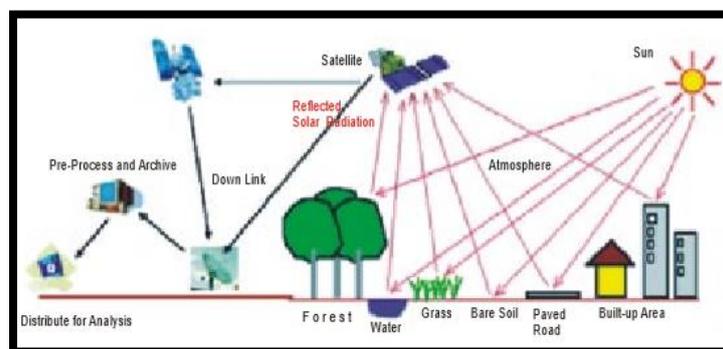


Figura 1: Componentes de un sistema de teledetección.

Fuente: (Aggarwal, 2003)

1.3.1.2 Espectro electromagnético

Es la energía que se propaga en una interrelación avanzada de los campos eléctricos y magnéticos (Kumar, 2013); (Centro de Ecología Aplicada, 2014) , es decir un sistema que clasifica, de acuerdo con la longitud de onda, toda la energía que se mueve, armónicamente, a la velocidad constante de la luz (Frank, 2017). Se puede dividir en distintas regiones atendiendo a las fuentes que producen las ondas electromagnéticas (Martínez, 2003).

Su rango inicia con las ondas largas hertzianas, pasando por el espectro visible, y finalmente alcanza los rayos UV, X y gamma (Belletti , Godino, & Blesio, 2016).

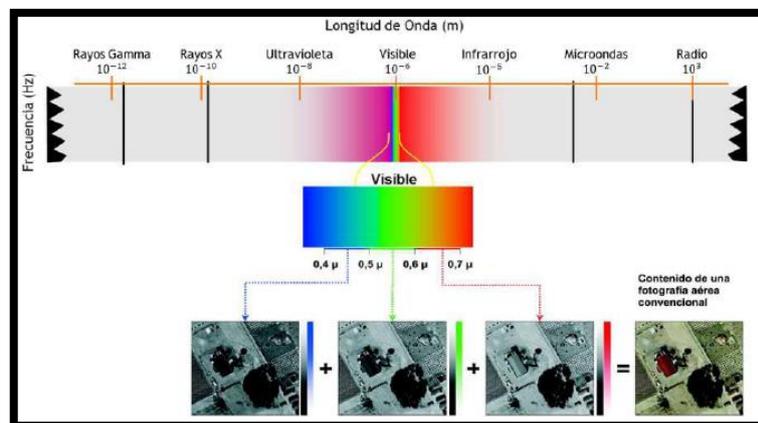


Figura 2: Espectro Electromagnético.

Fuente: (NASA, 2011)

1.3.2 Sensores

Una clasificación de la teledetección es de acuerdo al proceder dentro del ámbito de la radiación electromagnética (EMM) (Soria & Matar de Saquis , 2016).

1.3.2.1 Sensores pasivos

Estos dependen de una fuente de energía externa, siendo esta el sol (Soria & Matar de Saquis , 2016), el mismo que registra línea por línea, el EMM reflejado o emitido por la tierra y la atmósfera (Butler, Mouchot, & Barale, 1988). Los sensores pasivos transmitidos por el espacio

proporcionan la capacidad de obtener observaciones globales de la Tierra y de la atmósfera (Mai, 2017) .

1.3.3 Imágenes satelitales

Se las define como matrices de celdas llamadas píxeles, las mismas que están conformadas por un número establecido de filas y columnas. Estas determinan una área geográfica indivisible, estableciendo de tal manera las características mínimas que se diferencian en la escena digital (García & Barrera , 2015). Estas son captadas por un sensor que se encuentra en el satélite, el mismo que gira alrededor del planeta. (Cervantes , 2014).

La dimensión del píxel, depende del satélite y de la medida del sensor que capture la escena (Quiroz, 2011). El mismo incluye un dato numérico, que plasma la proporción de energía solar promedio que el área refleja, además está en función de lo que exista sobre ella. (García & Barrera , 2015).

1.3.3.1 Resolución de una imagen

Consiste en las especificaciones técnicas que tiene el satélite y el sensor que obtienen la información y esta se expresa de forma visual y digitalmente en la escena (Soria & Matar de Saquis , 2016). Estas características permiten luego obtener mayor o menor datos de la imagen.

- **Resolución espacial:** representa la cantidad del área o tamaño de la dimensión más pequeña en la superficie de la tierra sobre el cual el sensor puede realizar una medición independiente, el tamaño del píxel se expresa en metros (Liang, Li, & Wang, 2012).
- **Resolución espectral:** establece la cantidad y el ancho de las bandas espectrales que diferencia el sensor. A mayor resolución se obtendrá datos del comportamiento de una misma área en distintas bandas espectrales (Frank, 2017).
- **Resolución radiométrica:** Se refiere al cambio más pequeño en el nivel de intensidad que puede detectar el sistema de detección (Abdulrahman , 2010). Nos indica la medida

en bits, es la gamma de valores de brillo disponibles, que en la imagen corresponde con el alcance máximo de DN (Richards & Jia, 2006).

1.3.4 Plataformas espaciales

1.3.4.1 Landsat 7

El Landsat 7, se lanzó con éxito el 15 de abril de 1999, desde el Western Test Range de la Base de la Fuerza Aérea Vandenberg (USGS, 2017). El instrumento Landsat 7, Enhanced Thematic Mapper Plus (ETM+), tiene las mismas características de los instrumentos Thematic Mapper de Landsat 4 y 5, además fueron incluidas más características que lo hicieron más versátil y eficiente para estudios de cambio global, monitoreo y evaluación de la cobertura terrestre y mapeo de áreas grandes (Irons, Taylor, & Rocchio, 2018).

El registro de datos Landsat es importante para la teledetección terrestre y la investigación del cambio global debido a su resolución espacial relativamente fina, cobertura terrestre extensa y línea de base temporal en un momento en que se ha producido un cambio terrestre antropogénico significativo (Teillet, Barker, Markham, & Irish, 2001).

Landsat 7 consta de 6 bandas multiespectrales (Tabla 1) las mismas se combinan de diferentes maneras para conseguir varias tonalidades u alternativas de procesamiento, además se resalta por la adición de una banda pancromática con resolución espacial de 15 metros, y también consta de una banda térmica (Reuter, 2009).

Tabla 1. Distribución de las bandas ETM+

	BANDAS		LONGITUD DE ONDA	RESOLUCIÓN ESPACIAL
			(micrómetro)	metros
Landsat 7	Banda 1	Blue	0.45-0.52	30
	Banda 2	Green	0.52-0.60	30
	Banda 3	Red	0.63-0.69	30

ETM+	Banda 4	NIR	0.77-0.90	30
	Banda 5	SWIR 1	1.55-1.75	30
	Banda 6	Thermal	2.09-2.35	60
	Banda 7	SWIR 2	10.4-12.5	30
	Banda 8	Panchromatic	0.45-0.90	15

Fuente: (Wei , Gu, Meng , & Zhan, 2017); (Holden & Woodcock, 2016)

1.3.4.2 Landsat 8

Se lanzó el 11 de febrero de 2013, el mismo que se encuentra orbitando a una distancia de entre 701 y 703 km sobre la superficie terrestre, pasa por un mismo sitio del planeta cada 16 días y a los 8 días del paso de Landsat 7 (USGS, 2016).

Landsat 8 está formado por dos sensores: el OLI y el TIRS los mismo que visualizan simultáneamente todas las escenas, pero son capaces de trabajar independiente si surge un problema en cualquiera de los sensores (USGS, 2016).

Este sensor está formado por 8 bandas multiespectrales con una resolución 30 metros para las bandas de 1 a 7 y 9. Una banda nueva (coastal/aerosol) utilizada para investigaciones de aerosoles. La banda (cirrus) aplicada para detectar nubes. Además constan de la banda 8 (panchromatic) tiene una resolución espacial de 15 metros. Y finalmente para la obtención de temperatura superficial se emplean las bandas térmicas 10 y 11, las cuales tiene una resolución de 100 metros (Tabla 2) (Arizaga, 2013).

Tabla 2. Distribución de las bandas en OLI y TIRS

BANDAS		LONGITUD DE ONDA (MICRÓMETROS)	RESOLUCIÓN ESPACIAL (METROS)
Landsat 8 (OLI)	Banda 1	Coastal/aerosol	0.43-0.45
	Banda 2	Blue	0.45-0.51
	Banda 3	Green	0.53-0.59
	Banda 4	Red	0.64-0.67
	Banda 5	NIR	0.85-0.88

	Banda 6	SWIR 1	1.57-1.65	30
	Banda 7	SWIR 2	2.11-2.29	30
	Banda 8	Panchromatic	0.50-0.68	15
	Banda 9	Cirrus	1.36-1.38	30
(TIRS)	*Banda 10	Thermal (TIRS) 1	10.60-11.19	100
	*Banda 11	Thermal (TIRS) 2	11.50-12.51	100

* Las bandas TIRS se adquieren a una resolución de 100 metros, peros se vuelven a muestrear a 30 metros.

Fuente: (USGS, 2016)

1.3.4.3 Comparación de las bandas multiespectrales de las imágenes satelitales

Landsat 7 y Landsat 8

Históricamente, los investigadores han utilizado una variedad de enfoques para ayudar a normalizar los datos de series de tiempo, como la corrección radiométrica (Schott, Salvaggio, & Volchok, 1988).

Estos enfoques de normalización han sido evolucionados y reemplazados con la calibración de imágenes a reflectancia (Vogelmann , Gallant , Shi, & Zhu, 2016). Los primeros esfuerzos de la calibración radiométrica se centraron en el desarrollo de productos de reflectancia (Homer , Dewitz, Fry, & Coan, 2007), mientras que las actividades se centran en conjuntos de datos corregidos. (Zhu & Reed, 2012).

La serie de satélites Landsat 4-8, ha tenido una notable historia de actividades de calibración asociadas con ellos, y la calibración de sus sensores es muy bien entendida, es por eso que el Landsat 7 ETM+ fue colocado en una órbita muy cercana a la del Landsat 8 OLI con el fin de facilitar la calibración cruzada entre los instrumentos (Teillet et al., 2001). La calibración cruzada entre sensores puede basarse en mediciones de pre lanzamiento en el laboratorio utilizando fuentes comunes.

En un estudio realizado en el año 2016 en cuanto al análisis de las propiedades radiométricas del Landsat 8 frente al Landsat 7 de las 6 bandas se llegó a la conclusión de que las bandas

verdes, rojas y dos de infrarrojos de onda corta mostraron una concordancia especialmente alta entre los dos sensores, a excepción de la banda azul, seguida de la banda verde y luego de la banda roja que existe una mayor variabilidad, esto se debe a que las longitudes de onda de las bandas visibles para Landsat 7 y 8 son casi idénticas (Tabla 3), las explicaciones pueden deberse a las correcciones atmosféricas y las diferencias en las propiedades atmosféricas durante la adquisición de los datos (Vogelmann et al., 2016).

Estas diferencias generalmente tienen un mayor impacto en las bandas visibles que en el infrarrojo cercano y las ondas infrarrojo de onda corta. La variabilidad para el infrarrojo cercano y las dos bandas de onda corta e infrarroja es muy baja, lo que implica que la radiometría para estas bandas es bastante similar entre Landsat 7 y Landsat 8 (Vogelmann et al., 2016).

Tabla 3. Rangos de longitud de onda (en micrómetros) para las bandas de reflectancia comunes a los sensores en Landsats 4, 5, 7 y 8.

Banda espectral	Landsat 7 ETM+	Landsat 8 OLI
Azul-Blue (Banda 1 ETM+;Banda 2 OLI)	0.45-0.52	0.45-0.51
Verde-Green (Banda 2 ETM+;Banda 3 OLI)	0.52-0.60	0.53-0.59
Rojo-Red (Banda 3 ETM+; Banda 4 OLI)	0.63-0.69	0.64-0.67
Infrarrojo cercano-NIR (Banda 4 ETM+; Banda 5 OLI)	0.76-0.90	0.851-0.88
Infrarrojo de onda corta 1-SWIR1 (Banda 5 ETM+; Banda 6 OLI)	1.55-1.75	1.65-0.88
Infrarrojo de onda corta 2-SWIR2 (Banda 7 ETM+; Banda 7 OLI)	2.09-2.35	2.11-2.29

Fuente: (Vogelmann et al., 2016).

1.3.5 Pre procesamiento de imágenes satelitales

Es la primera etapa en la cual los valores brutos entregados por los sensores son corregidos (Rosales, Martínez , & Martínez , 2010), para reducir las distorsiones radiométricas y geométricas. Dichas distorsiones son las variaciones en los datos de brillo de los pixeles y esto

se da por la interferencia atmosférica y por consecuencia de los instrumentos (Campbell & Wynne, 2011).

1.3.5.1 Corrección radiométrica al Tope de la Atmósfera (TOA)

Las imágenes del sensor Landsat 7 y 8 tienen números digitales (DN) cuantificados y calibrados a escala. Los valores de DN se transforman a valores de radiancia y después a reflectancia. El primer paso convierte los datos originales en valores de radiancia a través de la información del *metadato*. La segunda transforma los valores obtenidos en el paso anterior a valores de reflectancia (Hameed & Hasan, 2014); (Abad, 2016). Para los sensores Landsat, los productos T1 los valores del *metadato* tienen componentes que transforman directamente los DN a valores de reflectancia, sin necesidad de convertir los valores de radiancia (USGS, 2016); (Abad, 2016).

1.3.5.2 Método de Chávez de sustracciones de píxeles oscuros

Es un método simple de corrección atmosférica ya que no necesita ninguna información sobre las condiciones atmosféricas. Se asume que hay píxeles donde la reflectividad es muy baja o nula y por tanto, cualquier valor de reflectividad obtenido en estos píxeles se considera que es debido a la dispersión atmosférica. Restando este valor a cada píxel se obtiene una corrección atmosférica sencilla ya que se está eliminando el efecto de la dispersión (Sendra, Camacho, Sánchez, & Muñoz, 2015).

Las entradas que se necesita para este modelo se basa principalmente en mediciones de imágenes y el *metadato*, que proporciona información importante, como la fecha de obtención de la imagen, el ángulo de elevación del sol, la ganancia y el sesgo (Ding, Shi, & Wang, 2015). Este método permite generar mejores resultados a partir del análisis de datos obtenidos por teledetección para estudios en los que las correcciones de dispersión atmosférica son críticas (Chavez, 1988).

1.3.6 Índices espectrales

Los índices espectrales son un instrumento que proporciona información de forma inmediata y no destructiva (Running, Thornton , Nemani, & Glassy, 2000); (Buzzi, Rueter, & Ghermandi, 2017) de áreas extensas con una resolución espacial regular y temporal alta (Irisarri , Oosterheld, Paruelo , & Texeira, 2012);(Buzzi et al., 2017).

Los índices espectrales pueden clasificarse en cuatro grupos según (Buzzi et al., 2017):

- a) Índices de vegetación simple: DVI, NDVI (Rouse, Haas, & Schell, 1973) y el RVI (Jordan , 1969).
- b) Índices de vegetación generados para acoplarse al suelo desnudo: SAVI y el MSAVI2 (Huete A. , 1988).
- c) Índices de vegetación que combinan correcciones para reducir la influencia del suelo desnudo o los aspectos atmosféricos: EVI (Huete, Didan, Miura, Rodriguez, & Gao, 2002) y el EVI2 (Jiang, Huete , & Didan , 2008).
- d) Índices de vegetación estiman para aumentar la relación lineal del índice y los factores biofísicos: GNDVI (Gitelson , Kaufman, & Merzlyak, 1996).

La aplicación de los índices de vegetación en la teledetección es habitual, es por esto que los cuatro índices pretenden aproximar correlación de los valores espectrales obtenidos por sensores remotos y los factores biofísicos (Romero, Paz, Palacios , & Bolaños, 2009).

1.3.6.1 Índice de vegetación normalizada (NDVI)

Es el más conocido y usado. Su fortaleza es su formulación de racionamiento, que permite la reducción de los efectos topográficos, las condiciones de iluminación, la sombra de la nube y la atenuación atmosférica (Testa , Soudani, Boschetti , & Borgogno, 2018). El NDVI generan rangos que van de -1 a 1, los valores cercanos a -1 representan masas de agua, y los valores

menores a 0.1 representan rocas y nieve, y vegetación sana de alta densidad como los bosques que dan valores superiores a 0.6 (Rugel , Henderson , Carpiano, & Brauer, 2017).

1.3.6.2 Índice de vegetación mejorado (EVI)

El EVI supera los problemas del NDVI (Adole, Dash, & Atkinson , 2018), este se diseñó con el objetivo de corregir la señal de vegetación con una mejora en áreas de biomasa alta y mejorar la vigilancia de la vegetación a través un desacoplamiento de la señal base del dosel y una reducción de las influencias de la atmósfera (Aulia, Setiawan, & Fatikhunnada, 2016).

1.3.6.3 Índice de Diferencia de Agua Normalizada Modificado (MNDWI)

Se ha demostrado que este índice es menos sensible a las impurezas de sub-píxeles que otros índices espectrales de agua (Dube & Mutanga, 2015). El valor de MNDWI varía de -1 a 1, con valores más grandes que indican una mayor fracción de agua en el pixel. Los pixeles de agua tienen valores de MNDWI positivos debido a su mayor reflectancia en la banda verde que en la banda SWIR, mientras que los pixeles no acuáticos (suelo y vegetación) tienen valores de MNDWI negativos debido a su menor reflectancia en la banda verde que en la banda SWIR (Xu H. , 2006).

1.3.6.4 Índice de vegetación ajustado al suelo (SAVI)

Propuesto por (Huete A. , 1988), su objetivo es minimizar los efectos de base del suelo en la señal de vegetación mediante la incorporación de un factor constante de ajuste al suelo L, el factor elegido depende de la densidad de la vegetación que uno desea analizar vegetación (Silleos , Gitas , Alexandridis , & Perakis , 2006); por lo tanto, es útil para la interpretación de varios parámetros de cultivos y para monitorear la variabilidad temporal y espacial de la vegetación (Gontia & Tiwari , 2010).

1.3.6.5 Índice de vegetación ajustado modificado (MSAVI)

Sugerido por (Qi , Chehbouni , Huete , Kerr, & Sorooshian, 1994) el mismo que consiste en la modificación del factor L del índice SAVI. Ambos están destinados a corregir mejor el brillo del fondo del suelo en diferentes condiciones de cobertura de vegetación (Silleos et al., 2006). La limitación particular de MSAVI es su desempeño como un estimador LAI (índice de área foliar) en doseles densos (Xie , Huang , Dash, & Song, 2015)

1.3.6.6 Índice de estrés hídrico (MSI)

Este índice relaciona la información referida a la producción de biomasa en los cultivos, captada por la porción del espectro rojo e infrarrojo cercano, y la referida a la humedad en la planta, detectable en el infrarrojo medio (FORMAGRO, 2015). El resultado explica que la momento que la vegetación se agota, existe un aumento del MSI (Gonzaga, 2014).

Presenta valores que varían entre -1 y 1, donde los valores aumentan a partir de que la vegetación se agota, un cultivo en buen estado hídrico tiene valores entre 0.2 7 0.45, mientras que la vegetación bajo estrés hídrico se observan dentro de los valores 0.45 y 0.6 (FORMAGRO, 2015); por lo tanto, este índice permite reconocer el aspecto de estrés hídrico de un cultivo o una cobertura vegetal, y está vinculado la planta con su temperatura y la disponibilidad de humedad en el suelo (Palacios, Bisher , & Cabrera , 2009); (Gonzaga, 2014).

1.3.6.7 Índice normalizado de áreas quemadas (NBR)

Es un cociente normalizado del mismo tipo que el NDVI, pero se fundamenta en el contraste espectral desde el NIR (0.78-0.90 μm) al SWIR1 (2.09-2.35 μm) (Hernández , González, Arbelo, & Nuñez, 2009). El mismo asemeja las áreas deterioradas por los incendios desde de las bandas, el cual su rango de variabilidad, al estar estandarizado, queda entre -1 y +1 (Manzo & López, 2013). En áreas quemadas, los valores de NBR disminuyen al mismo tiempo que aumenta la severidad del incendio (Escuin , Navarro , & Fernández , 2013)

El NBR mejora discriminación de regiones quemadas en contraposición con el NDVI localizados en el espectro visible ya que los datos del NIR y SWIR presenta un mejor contraste en estas grupo de superficies (Roy, Jin, Lewis, & Justice, 2005); (Manzo & López, 2013).

1.3.6.8 Índice de Diferencia Normalizada Edificada (NDBI)

Sirve para mapear automáticamente las áreas urbanizadas, el mismo fue propuesto por (Zha, Gao, & Ni , 2003), el cual aprovecha las respuestas espectrales únicas de las áreas edificadas y otras cubiertas terrestres (Chunyang , Peijun , Dingyong , & Yuanyuan , 2010).

Se basa en la respuesta espectral única de las tierras edificadas que tienen una mayor reflectancia en el rango de longitud de onda MIR en un rango de longitud de onda NIR. Este índice resalta las regiones urbanas en el cual se generan una reflectancia mayor en la región de infrarrojo de onda corta (SWIR), en contraposición con la región infrarroja cercana (NIR) (Zha et al., 2003).

1.3.7 Contaminación atmosférica

Se comprende como la aparición en el aire de elementos o formas de energía que involucren peligro o inconvenientes graves para la población y los bienes (Díez, 2018). La principal fuente de contaminación está asociado a las actividades antropogénicas derivadas principalmente por el uso de combustibles fósiles generando así diversos tipos de contaminantes que producen efectos sobre la salud (López & Pacheco, 2015)

Es por esto que en los últimos años, varios investigadores han divulgado que la dispersión de contaminantes por procesos de combustión, constituyen una de los motivos principales en la disminución de la calidad del aire (Toro, Ramírez, Quiceno, & Zuluaga, 2001)

De acuerdo a la Organización Mundial de la Salud la polución atmosférica es considerado como una de las prioridades mundiales importantes en salud (Regueira , Schlatter, & Diaz, 2009).

1.3.7.1 Dióxido de nitrógeno (NO₂)

El dióxido de nitrógeno está presente en las ciudades como uno de los elementos atmosféricos de gran relevancia, ya que su origen está ligado principalmente a los procesos de combustión (Esquivel & Cuba, 2006); (Regueira et al., 2009). Los óxidos de nitrógeno son muy reactivos y al absorber deterioran el sistema respiratorio (Regueira et al., 2009).

Para medir los efecto en la Salud de los contaminantes atmosféricos, es esencial monitorear, por un lado, la morbilidad y por otro conocer los niveles de los contaminantes atmosféricos (Prieto, Mancilla, & Astudillo, 2007), para lo cual en la Ciudad de Cuenca se ha implementado una red de vigilancia que establece 19 puntos de monitoreo pasivo para el NO₂ permitiendo medir valores de inmisión.

1.3.7.2 Normativa

La Normativa de Calidad del Aire Ambiente (NCAA) para fuentes móviles, establece el límite permitido de exposición de 200 µg/m³ a corto plazo dichos valores concuerdan con los fijados por la OMS, así mismo para periodos a largo plazo determina un máximo de concentración de 40 µg/m³ (Municipalidad de Cuenca , 2016).

1.3.8 Regresión de Mínimos cuadrados parciales (PLSR)

PLS fue desarrollado en la década de 1960 por Herman Wold como una técnica econométrica (Gallego, 2009), la misma que combina dos técnicas del análisis multivariante; el análisis de componentes principales y la regresión lineal múltiple (Valdéz, 2010). La regresión PLS se utiliza generalmente cuando se tiene un gran número de variables predictoras,

siendo esta una técnica de modelado lineal que se puede simular varias variables y procesar variables colineales fuertes y variables independientes ruidosas (Chen & Qi, 2017), esta no supone un error cero en los datos del predictor (Curran & Hay, 1986).

La regresión PLS asume que si existe un buen muestreo, los vectores en el espacio del predictor (independientemente del error) deberían proporcionar un poder predictivo superior para las observaciones adicionales, cuando se genere un grado alto de relación de las variables predictoras (SAS, 2000), lo que busca el PLS es un equilibrio entre la explicación de las variaciones en las variables tanto de respuesta como de predicción (SAS, 2000).

La diferencia que existe entre el PLSR y los componentes principales es que se basan únicamente en las variables X (Wolter, Townsend, & Sturtevant, 2008).

La regresión PLS es utilizada en diferentes estudios tal es el caso del estudio realizado por (Yonghua , Siong, & Xudong, 2008), donde se generó un modelo de regresión de mínimos cuadrados parciales basado en el análisis estadístico de la salinidad del suelo y el uso de imágenes satelitales Landsat, dando como resultado que el PLSR es una herramienta para recuperar la salinidad del suelo con resultados precisos. Así mismo un estudio realizado en Canadá por (Wolter et al., 2008), se ha empleado imágenes Landsat multitemporal para mapear la distribución y abundancia del gusano cogollero, en donde se ha utilizado la PLSR para establecer las correlaciones entre los valores en tierra y los datos del sensor Landsat. Finalmente un estudio realizado por (Burgos & Copo, 2017) en la ciudad de Quito donde han empleado el uso de imágenes satelitales Landsat 8 y el uso de la regresión por mínimos cuadrados parciales para la estimación de las concentraciones de ozono troposférico, generando así el modelo de predicción de O₃, en base a una matriz multivariable, mediante la regresión PLS.

1.3.8.1 Coeficiente de determinación (R^2)

Índice de la proporción de variación de la variable a explicar expresado por el modelo (Gallego, 2009).

Este se calcula como:

$$R^2 = \left(\frac{\sigma_{Y\hat{Y}}}{\sigma_Y \sigma_{\hat{Y}}} \right)^2 \quad (1)$$

Donde:

σ_Y = Desviación estándar de los datos medidos.

$\sigma_{\hat{Y}}$ = Desviación estándar de los datos predichos.

$\sigma_{Y\hat{Y}}$ = Covarianza entre los datos medidos y predichos.

1.3.8.2 Raíz cuadrada del error cuadrático medio de predicción (RMSEP)

Este método de validación consiste en calcular el grado de error entre los datos predichos \hat{y}_i y los medidos y_i para un grupo de p muestras de corroboración (Gallego, 2009). Su valor es calculado como:

$$RMSEP = \sqrt{\frac{1}{p} \sum_{i=1}^p (y_i - \hat{y}_i)^2} \quad (2)$$

CAPITULO 2. MATERIALES Y MÉTODOS

La metodología aplicada en el estudio se fundamentó en el procedimiento (Saraswat et al., 2017). En efecto, la investigación combina imágenes satelitales Landsat 7 y 8, en la que se usaron 6 bandas multiespectrales compatibles de los sensores. En la figura 3 se muestra en orden, cada uno de los métodos usados para la obtención de la concentración de dióxido de nitrógeno en el área urbana de la ciudad de Cuenca.

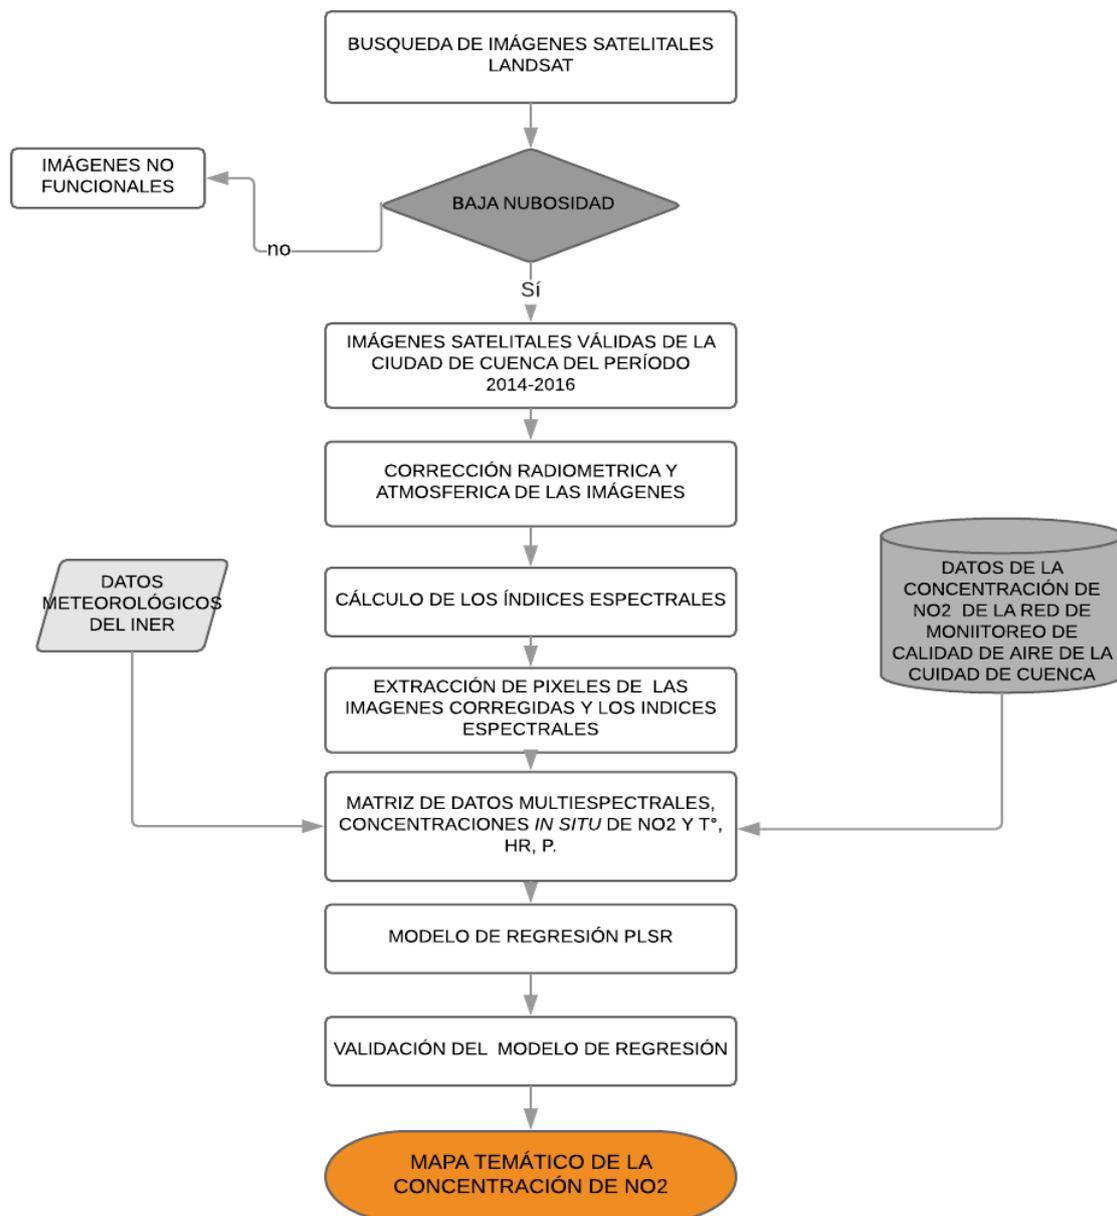


Figura 3. Metodología de investigación.

Elaborado por: Autor

2.1 Búsqueda de las imágenes satelitales Landsat

La exploración de información satelital se estableció en la ciudad de Cuenca, correspondiente al cantón Cuenca. La misma se encuentra a 2550 msnm, al sur del Ecuador, su extensión es de 72 km² aproximadamente (Abad, 2016). La ciudad posee una temperatura variable de 10 a 15 °C y pluviosidad alrededor de 700 mm (PDOT, 2015).

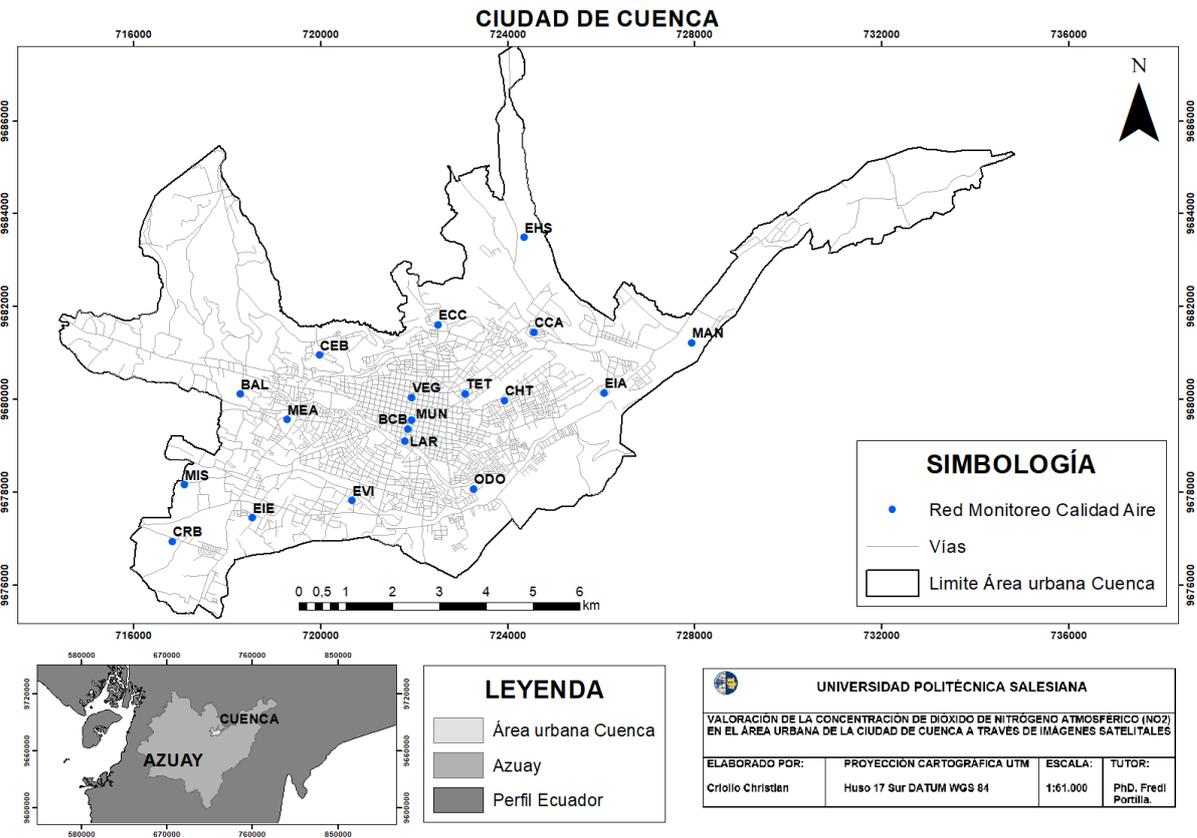


Figura 4. Ubicación del área de estudio. Fuente: (*Municipalidad de Cuenca*, 2016)

Elaborado por: Autor

Las imágenes satelitales empleadas en la presente investigación fueron Landsat 7 ETM+ y Landsat 8 OLI, las cuales se adquirieron del sitio web de la NASA y del Servicio Geológico de los Estados Unidos [<https://earthexplorer.usgs.gov/>]. Se especificó el periodo de búsqueda desde el 2014 al 2016, mediante un análisis de los datos espectrales válidos para el proyecto.

2.2 Imágenes satelitales válidas de la ciudad de Cuenca

Las imágenes recopiladas deben cumplir con un criterio de bajo porcentaje de nubosidad dentro del área de estudio, específicamente en los puntos de monitoreo pasivo de calidad del aire, para evitar obtener datos erróneos en la extracción de los píxeles.

La información obtenida se descarga en formato *TAR* comprimido, que contiene 7 bandas multiespectrales de Landsat OLI y 6 bandas multiespectrales de Landsat ETM, además incluye un archivo *MTL* con datos de los niveles digitales (ND), y características propias de cada imagen satelital.

Las imágenes Landsat ETM+ y OLI recolectadas son productos de categoría de colección T1, que ya cuentan con orto rectificación y corrección geométrica (He, Liang , Wang, Cao, & Gao, 2018).

2.3 Correcciones de las imágenes Landsat 7 y 8

Para estudios de estimaciones de concentraciones de contaminantes atmosféricos con imágenes satelitales se requiere de las correcciones para convertir los ND en unidades de reflectancia y eliminar distorsiones (Saraswat et al., 2017).

Las bandas multiespectrales de Landsat 7 y 8 utilizadas son: blue, green, red, nir, swir1 y swir2. Según se ha podido observar, la resolución radiométrica de las imágenes son similares en dichas bandas, por ende se realizan las correcciones radiométricas y atmosféricas.

2.3.1 Relleno de las imágenes satelitales Landsat 7

Las imágenes Landsat 7 necesitan una corrección previa para eliminar el bandeo producido por un error en el funcionamiento del sensor SLC-OFF. Para la corrección de los datos inválidos se utilizó el algoritmo *gap fill* aplicado en el software ArcGIS 10.3 (Vega, 2012).

2.3.2 Corrección de reflectancia al tope de la atmósfera (TOA)

El cálculo de la reflectancia existente de una cobertura absorbida por el sensor es restringido por los procesos atmosféricos, y también por ángulo de observación (Ariza, 2013); (Casasola, 2016) . De esta forma, la reflectancia TOA, incluyendo la rectificación para el ángulo solar es:

$$p\lambda = \frac{p\lambda'}{\cos(\theta_{SZ})} = \frac{p\lambda'}{\sin(\theta_{SE})} \quad (3)$$

Donde:

$P\lambda$ = Es el valor reflectancia planetaria o TOA, con corrección angular solar.

θ_{se} = Es el ángulo de elevación solar.

θ_{sz} = Es el ángulo solar zenith.

Es el ángulo solar zenith local, está en función al ángulo complementario de observación y se obtiene de:

$$\theta_{sz} = 90^a - \theta_{se} \quad (4)$$

2.3.3 Corrección atmosférica DOS1

Este método de corrección atmosférica, se considera de tipo absoluto, y se supone que si hay regiones en una imagen con datos bajos de reflectancia, cualquier reflectancia supuesta correspondería, al resultado de la dispersión atmosférica y estos valores son usados para calibrar la totalidad de la escena (Chavez , 1988); (Aguas, 2016). De esta manera la reflectancia de superficie terrestre (Frank, 2017) está dada por:

$$p_s = \frac{\pi*(L_\lambda - L_p)*d^2}{ESUN_\lambda*SEN(\theta_{SE})} \quad (5)$$

Donde:

L_p = Es el efecto bruma.

L_{λ} = Radiancia espacial en el sensor (radiancia en el satélite).

d = Distancia Tierra-Sol al instante de la captura de la escena.

$ESUN_{\lambda}$ = Irradiancia Media Solar exo atmosférica

θSE = Ángulo local de elevación del sol. El ángulo del centro del escenario en grados se proporciona en los *metadatos* (SUN_ELEVATION).

Las fórmulas descritas completamente para las correcciones radiométricas y atmosféricas de las imágenes satelitales, se muestran en el anexo 1.

Las correcciones radiométricas y atmosféricas se realizaron en el software QGIS 2.18.20 a través de la herramienta Semi-Automatic Classification Plugin.

2.4 Cálculo de los índices espectrales

Se calcularon 8 índices espectrales para las 8 imágenes satelitales Landsat ETM+ y Landsat OLI, para el periodo 2016, los cuales nos permiten identificar partículas en suspensión, es por esto que se aplicaron los siguientes:

- **Índice de vegetación normalizada (NDVI)**

Landsat 7

$$\frac{B4 - B3}{B4 + B3}$$

Fuente: (Rouse & Hass, 1973)

Landsat 8

$$\frac{B5 - B4}{B5 + B4}$$

Fuente: (Rugel et al. 2017)

- **Índice de vegetación mejorado (EVI)**

Landsat 7

$$2.5 \frac{(B4 - B3)}{(B4 + 6 * B3 - 7.5 * B2 + 1)}$$

Fuente: (Wei , Gu, Meng , & Zhan, 2017)

Landsat 8

$$2.5 \frac{(B5 - B4)}{(B5 + 6 * B4 - 7.5 * B3 + 1)}$$

Fuente: (Adole et al., 2018)

- **Índice de Diferencia de Agua Normalizada Modificado (MNDWI)**

Landsat 7

$$\frac{B2 - B5}{B2 + B5}$$

Fuente: (Xu H. , 2006).

Landsat 8

$$\frac{B3 - B6}{B3 + B6}$$

Fuente: (Mustafa & Hassoon , 2017)

- *Índice de vegetación ajustado al suelo (SAVI)*

Landsat 7

$$1.5 \frac{(B4 - B3)}{(B4 + B3 + 0.5)}$$

Fuente: (Wei , Gu, Meng , & Zhan, 2017)

Landsat 8

$$1.5 \frac{(B5 - B4)}{(B5 + B4 + 0.5)}$$

Fuente: (Gontia & Tiwari , 2010).

- *Índice de vegetación ajustado modificado (MSAVI)*

Landsat 7

$$\frac{(2 * B4 + 1 - \sqrt{(2 * B4 + 1)^2 - 8 * (B4 - B3)})}{2}$$

Fuente: (Yan , Wu, & Wang, 2013)

Landsat 8

$$\frac{(2 * B5 + 1 - \sqrt{(2 * B5 + 1)^2 - 8 * (B5 - B4)})}{2}$$

Fuente: (Xie et al., 2015)

- *Índice de estrés hídrico (MSI)*

Landsat 7

$$\frac{B4 - B5}{B4 + B5}$$

Fuente: (Gonzaga, 2014)

Landsat 8

$$\frac{B5 - B6}{B6 + B5}$$

Fuente: (Gonzaga, 2014)

- *Índice normalizado de áreas quemadas (NBR)*

Landsat 7

$$\frac{B4 - B7}{B4 + B7}$$

Fuente: (Peng, Zhiming, & Chiwei, 2018)

Landsat 8

$$\frac{B5 - B7}{B5 + B7}$$

Fuente: (Roy et al., 2005)

- **Índice de Diferencia Normalizada Edificada (NDBI)**

Landsat 7

$$\frac{B5 - B4}{B5 + B4}$$

Fuente: (Xu H. , 2008)

Landsat 8

$$\frac{B6 - B5}{B6 + B5}$$

Fuente: (Xu H. , 2008)

A través de software ArcGIS se realizó el cálculo mediante la herramienta *modelbuilder* dicho procedimiento se basa en una calculadora *raster* para el computo de los valores espectrales mediante imágenes satelitales.

2.5 Datos meteorológicos del cantón Cuenca

Los datos meteorológicos se adquieren del Instituto Nacional de Eficiencia Energética y Energías Renovables (INER). Existen 16 puntos de monitoreo de variables meteorológicas en el cantón Cuenca (INER, 2014). Para el estudio se eligieron las variables de precipitación (PP), humedad relativa (HR) y temperatura (T) debido a la correlación existente con el dióxido de nitrógeno.

Tabla 4. Puntos monitoreo de variables meteorológicas correspondiente al Cantón Cuenca

Estaciones	Coordenadas		Elevación (m)
	X	Y	
Nulti	729704	9682466	2623
Santa Ana	730085	9672006	2651
Llacao	730418	9685180	2542
Tixan - Chiquintad	723017	9686678	2725
CTS - Yanuncay	720504	9677509	2561
UPS el Vecino	723584	9680788	2556
Irquis - Victoria del Portete	713645	9659192	2665
Quingeo	729055	9664593	2895
Cumbe	719190	9656242	3179
Baños	712899	9672817	3062

San Joaquín	714405	9680807	2764
Sayausi	715974	9681200	2727
Turi	721103	9674971	2768
Sinincay	689859	9672550	3720
Molleturo	676435	9692152	3524

Fuente: (Calle & Tinoco, 2018)

Elaborado por: Autor

Con los valores *in situ* de las estaciones meteorológicas se generó un modelo de interpolación en el software ArcGIS con la herramienta *kriging* que establece predicciones aplicando un método estadístico.

2.6 Red de calidad de aire de la ciudad de Cuenca

La red de monitoreo pasivo de Cuenca es operada por la EMOV EP. Cuenta con 19 puntos de registro de concentración de NO₂ que muestrea dos veces por mes durante 10 a 12 días consecutivos, y obtiene valores promedios mensuales (Municipalidad de Cuenca, 2016). En la siguiente tabla 5 se observa los puntos de monitoreo de NO₂ en Cuenca.

Tabla 5. Puntos de monitoreo pasivo NO₂ en la ciudad de Cuenca

Código	Nombre	Escala
EVI	Escuela Velasco Ibarra	Vecinal
MEA	Mercado el Arenal	Vecinal
ODO	Facultad de Odontología- U de Cuenca	Vecinal
CHT	Colegio Herlinda Toral	Vecinal
TET	Terminal Terrestre	Vecinal
MUN	Municipio	Urbana, vecinal
EIE	Escuela Ignacio Escandón	Urbana, vecinal
CRB	Colegio Rafael Borja	Vecinal
BAL	Balzay CEA-U de Cuenca	Vecinal
EIA	Escuela Ignacio Andrade	Vecinal
CCA	Colegio Carlos Arizaga Vega	Urbana, vecinal

ECC	Escuela Carlos Crespi II	Vecinal
EHS	Escuela Héctor Sempértegui	Vecinal
BCB	Estación de Bomberos	Microescala
LAR	Calle Larga	Microescala
VEG	Vega Muñoz	Microescala
MAN	Machángara	Vecinal
CEB	Cebollar	Vecinal
MIS	Misicata	Vecinal

Fuente: (Municipalidad de Cuenca , 2016)

Elaborado por: Autor

2.7 Extracciones de valores de las imágenes satelitales, índices espectrales y variables meteorológicas

Las imágenes satelitales corregidas la reflectancia TOA y atmosférica junto con los índices espectrales y variables meteorológicas (T, HR, PP), se extraen los valores en función de las estaciones de monitoreo pasivo de NO₂ de la ciudad de Cuenca, con la función *Extract Multi Values to Points* del software ArcGIS. (González M. , 2016)

2.8 Base de datos

La matriz multivariante se generó con datos de NO₂, las bandas multiespectrales corregidas reflectancia en el TOA y atmosférica, los índices espectrales EVI, MNDWI, MSAVI, MSI, NBR, NDBI, NDVI, SAVI además de las variables meteorológicas de T, HR, PP. La matriz consta de 23 variables independientes y una dependiente, además en figuran 19 observaciones que corresponden a los puntos de monitoreo pasivo en el área urbana de Cuenca durante el periodo de estudio.

2.9 Modelo de regresión y validación

La matriz multivariante generada en el procedimiento anterior se utiliza para emplear un modelo PLSR, el cual está compuesto por una mezcla de análisis de componentes principales y regresión lineal múltiple (Abdi & Williams, 2013). Los modelos PLSR generan estabilización

de los coeficientes estimados haciendo que sea un modelo más sólido que los tradicionales como: regresión lineal múltiple y regresión de principales componentes (Wolter et al., 2008).

2.9.1 Validación

En el estudio realizado por (Yonghua et al., 2008), explican que para métodos de análisis de regresión multivariante se pueden validar el modelo mediante la precisión de 3 índices: RMSEP, R² y variancia explicada.

2.10 Generación del mapa temático de la concentración de NO₂

Este procedimiento se realiza aplicando el modelo PLSR, empleando el software ArcGIS mediante la función modelbuilder para generar el mapa de concentración de NO₂ del periodo de estudio. Además se generó un mapa de riesgos de la ciudad de Cuenca aplicando los límites establecidos por la normativa ecuatoriana.

CAPITULO 3. RESULTADOS

3.1 Imágenes satelitales válidas

Para el presente trabajo se recolectaron imágenes Landsat 7 y 8, con un porcentaje de nubosidad hasta del 30 % dentro del área de estudio, desde el periodo 2014 al 2016. El listado de las imágenes preseleccionadas se presenta en la tabla 6,7.

Tabla 6. Imágenes satelitales de Landsat 7 del periodo 2014-2016

IMAGEN_LANDSAT_7	NUBOSIDAD	FECHA
LE07_L1TP_010062_20140328_20161117_01_T1	29.00	28/3/2014
LE07_L1TP_010062_20140702_20161112_01_T1	46.00	2/7/2014
LE07_L1TP_010062_20150502_20161026_01_T1	50.00	2/5/2015
LE07_L1TP_010062_20150822_20161026_01_T1	34.00	22/8/015
LE07_L1TP_010062_20160824_20161007_01_T1	29.00	24/8/2016
LE07_L1TP_010062_20161027_20161122_01_T1	18.00	27/10/2016
LE07_L1TP_010062_20161112_20170302_01_T1	37.00	12/11/2016

Elaborado por: Autor

Se obtuvieron 7 escenas Landsat 7 del período estudiado, en el cual, en el año 2016 se recolectó la mayor cantidad de información satelital.

Tabla 7. Imágenes satelitales de LANDSAT 8 del periodo 2014-2016

IMAGEN_LANDSAT_8	NUBOSIDAD	FECHA
LC08_L1TP_010062_20140304_20170425_01_T1	57.59	4/3/2014
LC08_L1TP_010062_20140608_20170422_01_T1	52.72	8/6/2014
LC08_L1TP_010062_20140726_20170420_01_T1	35.79	26/7/2014
LC08_L1TP_010062_20141030_20170418_01_T1	41.71	30/10/2014
LC08_L1TP_010062_20150219_20170412_01_T1	66.87	19/2/2015
LC08_L1TP_010062_20150713_20170407_01_T1	11.65	13/7/2015
LC08_L1TP_010062_20150915_20170404_01_T1	32.28	15/9/2015
LC08_L1TP_010062_20151102_20170402_01_T1	44.43	2/11/2015
LC08_L1TP_010062_20160105_20170404_01_T1	55.25	5/1/2016
LC08_L1TP_010062_20160206_20170330_01_T1	61.83	6/2/2016

LC08_L1TP_010062_20160528_20170324_01_T1	60.55	28/5/2016
LC08_L1TP_010062_20161019_20170319_01_T1	43.61	19/10/2016
LC08_L1TP_010062_20161120_20170318_01_T1	27.75	20/11/2016

Elaborado por: Autor

Se recolectaron 13 imágenes Landsat 8 desde el 2014 hasta el 2016, y como se muestra en la tabla 7 la mayor información y la menor proporción de nubes fue en el último año.

Para la elección de las imágenes válidas dentro de un año se basó en dos razones: la primera por la mayor cantidad recolectada en dicho periodo y la segunda por el menor porcentaje de nubes dentro del área de estudio. Las imágenes seleccionadas para el presente proyecto son 8, y estas son obtenidas desde el 5 de enero del 2016 hasta el 20 de noviembre del 2016. Se consiguieron 5 que corresponden a las imágenes Landsat 8 y las 3 últimas a Landsat 7.

3.2 Pre procesamiento de las imágenes satelitales

3.2.1 Corrección de bandeo de Imágenes Landsat 7

El relleno de imágenes satelitales solo se aplica para las Landsat 7 debido al error de bandeo, es por esto que se aplica la corrección del algoritmo *gapfill* de (Vega, 2012). Esta es una herramienta que se aplica en el software ArcGIS.

Para la corrección se aplicó 3 procedimientos: en el primero se debe realizar la selección de banda, por banda que se desea rellenar, y para esto se debe elegir las bandas multiespectrales originales de Landsat 7.

El siguiente procedimiento crea una tabla de atributos y se aplica la herramienta *SetNull* que elimina los valores de las celdas iguales a 0, y por último aplica la función *Filter Low* que genera un relleno de las imágenes mediante interpolación.

3.2.2. Corrección de reflectancia al tope de la atmósfera (TOA)

Para este proceso se utilizaron las 5 imágenes originales Landsat 8 y las 3 imágenes Landsat 7 corregidas en el apartado 3.1.

Los datos se obtuvieron del promedio de las imágenes Landsat 7 y 8 del año 2016. Dichos valores extraídos se muestran en la tabla 8 y éstos tienen un rango de 0 a 1 debido a la corrección TOA.

Tabla 8. Valores de reflectada TOA extraídos del periodo 2016

Estación	BLUE TOA	GREEN TOA	RED TOA	NIR TOA	SWIR1 TOA	SWIR2 TOA
EVI	0,1380	0,1404	0,1461	0,2189	0,2327	0,1964
MEA	0,2049	0,2041	0,2169	0,2439	0,2889	0,2634
ODO	0,1110	0,1105	0,1188	0,1900	0,1937	0,1578
CHT	0,1330	0,1330	0,1533	0,1762	0,2261	0,2042
TET	0,1894	0,1898	0,2017	0,2128	0,3427	0,3708
MUN	0,1165	0,1117	0,1281	0,1483	0,2000	0,1801
EIE	0,1418	0,1402	0,1491	0,1844	0,1990	0,1795
CRB	0,1619	0,1591	0,1637	0,2623	0,2772	0,2095
BAL	0,0920	0,0867	0,0828	0,1865	0,1582	0,1100
EIA	0,1765	0,1817	0,1955	0,2321	0,2741	0,2267
CCA	0,1258	0,1259	0,1548	0,1918	0,2081	0,1762
ECC	0,1500	0,1584	0,1609	0,2952	0,2634	0,1828
EHS	0,1237	0,1375	0,1457	0,2670	0,2631	0,1932
BCB	0,1314	0,1290	0,1414	0,1665	0,2019	0,1822
LAR	0,1172	0,1143	0,1347	0,1493	0,1888	0,1700
VEG	0,1139	0,1110	0,1306	0,1655	0,2082	0,1815
MAN	0,1155	0,1224	0,1629	0,2376	0,2773	0,2382
CEB	0,1163	0,1208	0,1253	0,2133	0,2122	0,1584
MIS	0,0975	0,1027	0,0997	0,2362	0,2054	0,1286

Elaborado por: Autor

3.2.3 Corrección atmosférica DOS1

Las imágenes son las mismas que se utilizan en el procedimiento anterior. Para calcular el valor del pixel corregido atmosféricamente se aplicó la herramienta *Semi-Automatic Classification Plugin* en el software QGIS versión 2.18.20 que utiliza las bandas junto con los archivos *metadato* (MTL.) que contienen características propias de las bandas. En este proceso se aplica la ecuación (5) para estimar los valores corregidos, en la tabla 9 se muestran dicho valores.

Tabla 9. Valores atmosféricos extraídos del periodo 2016

Estación	BLUE ATM	GREEN ATM	RED ATM	NIR ATM	SWIR1 ATM	SWIR2 ATM
EVI	0,1044	0,1331	0,1517	0,2458	0,2645	0,2333
MEA	0,1275	0,1409	0,2286	0,2688	0,3182	0,2983
ODO	0,0703	0,0944	0,1224	0,2142	0,2178	0,1837
CHT	0,1040	0,1261	0,1648	0,2035	0,2584	0,2413
TET	0,1228	0,1331	0,2198	0,2468	0,3880	0,4356
MUN	0,0927	0,1148	0,1310	0,1657	0,2235	0,2084
EIE	0,1021	0,1296	0,1557	0,2091	0,2235	0,2079
CRB	0,1286	0,1584	0,1726	0,2977	0,3084	0,2416
BAL	0,0507	0,0689	0,0803	0,2112	0,1798	0,1296
EIA	0,1139	0,2423	0,2089	0,2696	0,3036	0,2603
CCA	0,0905	0,1227	0,1648	0,2193	0,2361	0,2070
ECC	0,0677	0,1072	0,1631	0,3332	0,2924	0,2080
EHS	0,0880	0,1251	0,1539	0,3012	0,2910	0,2203
BCB	0,1318	0,1425	0,1453	0,1841	0,2254	0,2105
LAR	0,0831	0,0992	0,1411	0,1703	0,2115	0,1975
VEG	0,0784	0,0974	0,1343	0,1867	0,2331	0,2103
MAN	0,0863	0,1170	0,1740	0,2691	0,3090	0,2733
CEB	0,0848	0,1222	0,1299	0,2422	0,2386	0,1848
MIS	0,0535	0,0837	0,1012	0,2677	0,2315	0,1514

Elaborado por: Autor

3.3 Índices espectrales

Los índices espectrales se calcularon con las ecuaciones descritas en la sección (2.4), para ello solo se utilizaron las bandas green, red, nir, swir1, swir2. Los valores obtenidos van desde -1 a 1, siendo -1 la ausencia, y 1 la presencia de agua, suelo o vegetación, etc. dependiendo del índice aplicado. Después de las consideraciones anteriores se realizó el promedio de índice por índice, cuyos resultados se observan en la tabla 10.

Tabla 10. Valores promedio de los Índices espectrales

Estación	EVI	MNDWI	MSAVI	MSI	NBR	NDBI	NDVI	SAVI
EVI	0,1023	-0,3296	0,6122	0,5869	0,0299	0,0397	0,2357	0,1562
MEA	0,0415	-0,1716	0,5530	0,7183	-0,0673	0,0952	0,0783	0,0573
ODO	0,1001	-0,3593	0,5919	0,6337	0,0777	0,0079	0,2733	0,1645
CHT	0,0404	-0,2560	0,4865	0,6978	-0,0734	0,1073	0,0986	0,0644
TET	0,0327	-0,1793	0,4926	0,8677	-0,2595	0,2086	0,0488	0,0392
MUN	0,0385	-0,2977	0,4726	0,7821	-0,1143	0,1485	0,1175	0,0654
EIE	0,0640	-0,2249	0,5217	0,6663	0,0026	0,0337	0,1462	0,0923
CRB	0,1497	-0,3101	0,6789	0,6476	0,1043	0,0173	0,2661	0,1932
BAL	0,1531	-0,4557	0,6576	0,5223	0,2425	-0,0872	0,4410	0,2411
EIA	0,0744	-0,2267	0,5527	0,7215	0,0016	0,0707	0,1332	0,0917
CCA	0,0538	-0,3090	0,5253	0,6272	0,0353	0,0292	0,1430	0,0921
ECC	0,1842	-0,4089	0,7826	0,5734	0,2561	-0,0727	0,3944	0,2705
EHS	0,1396	-0,3759	0,7218	0,6290	0,1562	-0,0179	0,3231	0,2310
BCB	0,0414	-0,2493	0,4948	0,7176	-0,0724	0,1049	0,1155	0,0691
LAR	0,0325	-0,2565	0,4588	0,8061	-0,0767	0,1105	0,0940	0,0538
VEG	0,0581	-0,3338	0,5104	0,7540	-0,0596	0,1106	0,1632	0,0956
MAN	0,0814	-0,4178	0,6207	0,6963	-0,0070	0,0686	0,2155	0,1514
CEB	0,1210	-0,3672	0,6362	0,5999	0,1354	-0,0083	0,3036	0,1934
MIS	0,1752	-0,4699	0,7449	0,5549	0,2778	-0,0716	0,4507	0,2866

Elaborado por: Autor

3.4 Variables meteorológicas

Para calcular las variables meteorológicas (T, HR, PP), se consideró 15 puntos de monitoreo distribuidos en el cantón Cuenca (ver Anexo 2). Los valores presentados en la tabla 11 se aplicaron para generar un modelo de interpolación en el software ArcGIS, en este procedimiento se ajusta el tamaño de celda a 30 x 30, valores que corresponde a la dimensión del pixel de las imágenes satelitales, con el cual se genera una distribución espacial de las variables.

Tabla 11. Valores promedio de las variables meteorológicas del periodo 2016 del Cantón Cuenca

Estación Meteorológica	PP	HR	T
Nulti	625,00	77,32	14,65
Santa Ana	834,60	78,82	13,69
Llacao	973,20	75,13	15,10
Tixan – Chiquintad	751,20	76,80	13,96
CTS – Yanuncay	826,90	73,06	15,26
UPS-el Vecino	841,10	69,31	15,68
Irquis – Victoria del Portete	998,20	84,83	12,78
Quingeo	714,00	80,86	12,47
Cumbe	765,20	86,64	10,61
Baños	891,50	84,56	11,34
San Joaquín	997,30	78,54	13,39
Sayausí	864,90	76,33	13,89
Turi	894,60	81,41	13,56
Sinincay	934,40	75,61	14,25
Molleturo	536,80	85,87	9,17

Fuente: INER

Elaborado por: Autor

Después de lo anterior expuesto se obtiene el área de interés a través de la función *extract by mask*, dichas áreas interpoladas se muestra en el anexo 3. Al final se extraen los valores de PP, HR y T del área urbana de Cuenca, los cuales se observan en la siguiente tabla 12.

Tabla 12. Valores de variables meteorológicas del periodo 2016 de la ciudad de Cuenca

Estación	PP	HR	T
EVI	825,33	73,22	15,22
MEA	787,79	75,21	14,53
ODO	788,57	74,40	14,78
CHT	818,10	70,33	15,49
TET	846,53	70,24	15,50
MUN	845,19	73,10	15,00
EIE	850,69	75,63	14,52
CRB	934,80	77,32	13,93
BAL	785,38	76,13	14,16
EIA	673,35	73,63	14,93
CCA	801,89	70,89	15,39
ECC	857,88	71,29	15,29
EHS	801,49	74,09	14,75
BCB	843,05	73,38	14,96
LAR	839,89	73,71	14,93
VEG	849,07	72,55	15,08
MAN	582,53	76,09	14,68
CEB	783,18	74,93	14,52
MIS	882,77	76,79	14,03

Elaborado por: Autor

3.5 Estaciones de monitoreo de NO₂

Los datos *in situ* del NO₂ se obtuvieron de 19 estaciones pasivas de monitoreo de la EMOV EP que están distribuidas por la ciudad de Cuenca. Los meses seleccionados dependen de las fechas de las imágenes satelitales expuestas en el apartado 3.1, con dicha información se calcula el promedio del contaminante por punto de muestreo en el año 2016, la información se observa en la tabla 13.

Tabla 13. Concentración de NO₂ del periodo 2016

ESTACIÓN	ENERO	FEBRERO	MAYO	AGOSTO	OCTUBRE	NOVIEMBRE	PROMEDIO *
EVI	22,80	18,20	21,10	20,00	22,60	17,80	20,42
MEA	29,50	23,10	23,20	19,20	26,70	22,80	24,08
ODO	23,30	15,40	19,70	17,00	22,60	25,90	20,65
CHT	22,50	16,30	21,80	16,10	24,30	21,90	20,48
TET	28,70	24,80	22,80	24,80	32,40	29,10	27,10
MUN	23,70	18,50	20,80	20,00	25,30	22,80	21,85
EIE	27,20	21,10	23,30	21,40	24,60	22,80	23,40
CRB	15,50	14,70	21,10	18,10	15,30	11,00	15,95
BAL	22,10	14,00	20,60	17,30	19,00	17,60	18,43
EIA	20,40	16,40	18,80	17,80	20,30	18,50	18,70
CCA	25,00	21,30	19,30	14,60	26,00	28,90	22,52
ECC	21,80	15,20	15,30	13,20	23,10	21,00	18,27
EHS	17,70	10,30	11,80	18,00	17,50	13,90	14,87
BCB	51,80	36,30	32,30	39,30	52,70	54,30	44,45
LAR	37,80	29,50	27,30	28,30	38,70	38,30	33,32
VEG	44,80	39,50	37,10	40,90	51,90	47,80	43,67
MAN	19,10	12,90	14,50	10,80	17,40	16,30	15,17
CEB	23,00	15,40	17,90	14,60	20,40	19,40	18,45
MIS	16,80	12,70	18,80	13,40	14,30	11,60	14,60

* Los datos calculado con los valores *in situ* de los puntos de monitoreo de NO₂ Fuente: (Municipalidad de Cuenca , 2016)

Elaborado por: Autor

A continuación, en la figura 5 se observa las concentraciones anuales por punto de muestreo de NO₂, contrastado con el límite determinado por la normativa Nacional y de la OMS. Se identifica que las estaciones BCB, VEG sobrepasan el límite de 40 µg/m³ establecido para periodos largos de exposición. Las demás estaciones muestran valores por debajo de lo normado.

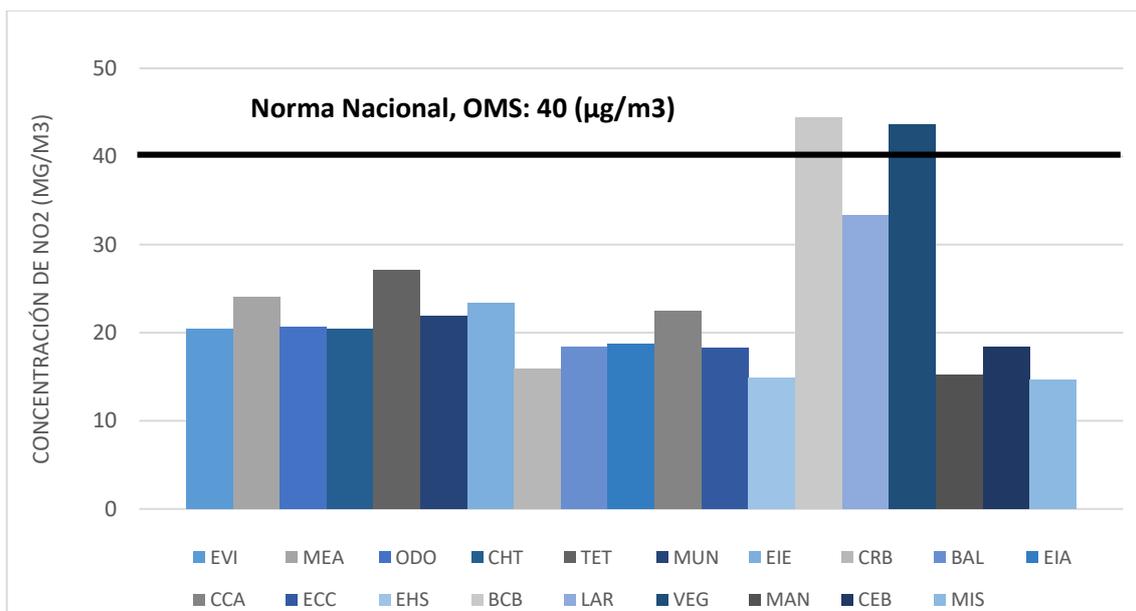


Figura 5. Concentraciones de NO₂ de las estaciones pasivas de monitoreo

Fuente: (Municipalidad de Cuenca , 2016)

3.6 Modelo de Regresión de Mínimos Cuadrados Parciales (PLSR)

El modelo PLSR se aplica con la matriz (ver Anexo 4) formado por 24 variables y 19 observaciones, en la cual se distingue 1 variable a explicar siendo esta el NO₂ y 23 predictores que están divididas en 12 bandas multispectrales (Blue-TOA, Green-TOA, Red-TOA, Nir-TOA_Swir1-TOA, Swir2-TOA, Blue-ATM, Green-ATM, Red-ATM, Nir-ATM, Swir1-ATM, Swir2-ATM), 8 índices espectrales (EVI, MNDWI, MSAVI, MSI, NBR, NDBI, NDVI, SAVI) y 3 variables meteorológicas (PP, HR, T).

La regresión de mínimos cuadrados parciales se aplicó en el software R versión 3.5.1 mediante el paquete PLS, en la cual se ingresa la matriz del Anexo 4, mediante la instrucción `NO2_2016 <- read.csv2("~/BASE_DATOS_2016/NO2_2016.csv", row.names=1)`. Como paso siguiente se fijó el nombre de las variables a través del comando `attach`. Finalmente se emplea el modelo de la siguiente manera: `modelo-PLSR=plsr(NO2~. data=NO2_2016, scale=TRUE)`.

Con el comando *scale* todos los datos de la matriz multivariante se estandarizan, mediante la división por su desviación estándar, para que todos los datos estén en el mismo rango.

El modelo PLSR está conformado por cargas que representa la proporción de información que contribuye cada variable predictora a los distintos componentes. En la tabla 14 se presentan los datos de las cargas antes mencionadas.

Tabla 14. Valores de las cargas de las variables del modelo PLSR de NO₂

Variables	Comp 1	Comp 2	Comp 3	Comp 4	Comp 5	Comp 6	Comp 7	Comp 8	Comp 9	Comp 10	Comp 11	Comp 12	Comp 13	Comp 14	Comp 15	Comp 16	Comp 17	Comp 18
BLUE-TOA	-	-0,30	0,27	-0,40	0,30	-	0,15	-0,11	0,43	-0,32	0,14	-0,48	0,51	-0,33	-	0,13	0,31	-0,16
GREEN-TOA	-	-0,32	0,24	-0,29	0,29	-	-	-0,11	0,32	-0,36	0,20	0,21	0,17	-	-	-	-0,22	0,51
RED-TOA	0,11	-0,32	-	-	0,23	-	-	-0,31	0,21	0,11	-	-0,28	0,23	-	0,16	-	-0,42	-0,23
NIR-TOA	-0,26	-0,23	0,13	0,25	-	-	-0,10	-0,14	-0,14	-	-	0,25	-0,15	-0,22	0,27	-0,12	0,15	0,22
SWIR1-TOA	-	-0,34	-	0,25	-0,37	0,12	-	-	-	-	-0,18	-	0,17	-	0,16	-	0,37	0,27
SWIR2-TOA	0,15	-0,29	-	-0,10	-0,44	0,34	-	0,11	-	-	-	0,10	-0,27	-0,12	0,23	-	-0,19	-
BLUE-ATM	0,18	-0,22	0,23	-	0,29	-0,42	0,31	0,22	-1,23	0,70	-0,38	0,12	-0,17	0,17	-	-	-	-
GREEN-ATM	-	-0,24	-	-0,12	0,54	-1,00	-	0,61	0,15	-0,20	0,22	-	-	-0,16	-	-	-	-
RED-ATM	0,12	-0,32	-	-	0,17	-	-	-0,30	0,17	0,15	-	-0,16	-	0,17	-0,16	0,33	-	-0,26
NIR-ATM	-0,25	-0,23	0,12	0,16	-	-	-0,13	-	-	-	-	-	-0,28	0,12	-	-0,30	-	-0,21
SWIR1-ATM	-	-0,33	-	0,14	-0,40	0,14	-	0,10	-0,15	-	-0,19	-	0,16	0,18	-0,28	-	0,19	-
SWIR2-ATM	0,15	-0,29	-	-0,20	-0,47	0,35	-	0,15	-	-	0,12	-	-0,27	0,15	-0,24	-	-0,15	-
EVI	-0,34	-	0,16	-	-	-	-	0,27	0,11	-0,17	-	-0,69	-0,20	0,40	-	-	-0,29	0,12
MNDWI	0,27	-0,16	0,21	-0,47	0,33	-0,20	0,17	-0,17	0,24	-0,30	-0,18	0,60	-0,95	0,45	-	-	-	-0,26
MSAVI	-0,34	-	0,11	0,25	-	0,10	-	-	-0,18	-	0,14	0,34	-	-0,26	-	-	-	-0,23
MSI	0,29	-0,11	-	0,92	-0,41	-	-	-	0,90	0,36	-0,13	0,17	-0,45	0,26	-	-	-	-
NBR	-0,32	0,10	-	-0,18	0,24	-	-	-	0,33	-	-0,30	0,28	-	0,19	-0,68	-	-	0,11
NDBI	0,32	-0,10	-	0,49	-0,32	-	-	-	-0,28	-0,15	0,17	-0,14	0,71	-0,29	-0,23	-	-0,31	-0,21
NDVI	0,32	0,11	-	-	-0,12	0,17	-	0,25	0,12	-0,18	-	0,11	0,16	-	-	-0,43	0,27	-0,47
SAVI	-0,34	-	-	0,11	-0,13	-	-	0,19	-	-	-	0,21	-0,17	0,11	-	0,83	-0,29	-
PP	-	0,10	0,90	-0,26	-0,15	-0,14	-	-	-	-	0,20	-0,10	0,12	-	-	-	-	-
HR	-0,18	-	-0,15	0,25	-0,15	-0,56	0,77	-0,48	-0,13	-	0,63	-0,28	-0,31	0,36	-0,23	-	0,15	-
T	0,20	-	-	-	0,18	0,55	-0,75	0,41	-0,40	-	0,57	-0,24	-0,42	0,43	-0,25	-	0,19	-

Elaborado por: Autor

Al evaluar la tabla 14 se observa que las variables predictoras blue-TOA, MNDWI, nir-TOA, HR están presente en la mayor cantidad de componentes, esto explica la importancia que tiene en el modelo PLSR mientras tanto swir1-TOA, green-ATM, nir-ATM, MSAVI, SAVI, PP son las variables que menos información aportan.

Las cargas de las variables de los 3 componentes que se indican en la figura 6, y al analizar el gráfico se puede establecer que en los primeros 2 componentes no existe una discrepancia relevante, ya que la proporción de variancia explicada es muy similar. Según (Alciatui , Escobar , De la Cruz, & Rincón , 2003) los primeros componentes contienen la información más relevante resumida mientras que los últimos contienen el ruido que significa malos predictores.

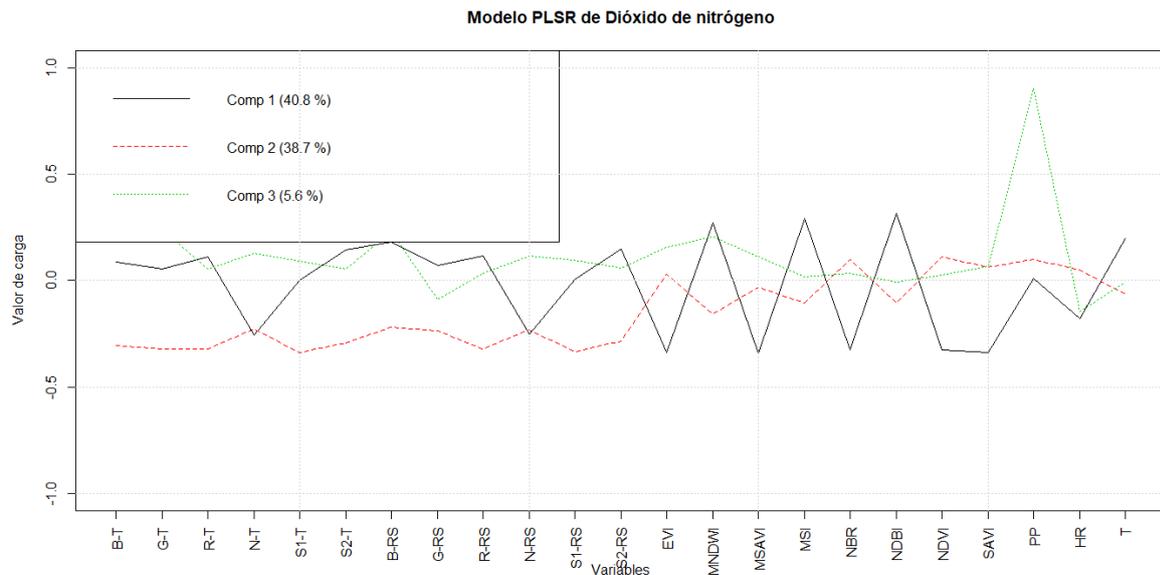


Figura 6. Cargas de las variables predictoras del modelo PLSR

Elaborado por: Autor

El resumen la regresión de mínimos cuadrados parciales se visualiza en la tabla 15, que al analizar los 3 componentes ya se explica el 85 % de la variancia de las variables, lo cual nos indica que la variancia residual es explicada por los componentes faltantes.

Para el estudio se tomó en cuenta 13 componentes o variables latentes que expresan el 99,99% de la variabilidad de las variables predictoras y el 77,78 % de la variancia de la variable de respuesta, como se explica en la tabla 15. Los compontes necesarios para la predicción del NO₂ se eligieron en función a los criterios establecidos por (Jing & Chen , 2016), los cuales se indicarán en la sección de validación del modelo PLSR.

Tabla 15. Variancia explicada del modelo PLSR de NO₂ según el número de componentes

	COMPONENTES																	
	CO MP 1	CO MP 2	CO MP 3	CO MP 4	CO MP 5	CO MP 6	CO MP 7	CO MP 8	CO MP 9	CO MP 10	CO MP 11	CO MP 12	CO MP 13	CO MP 14	CO MP 15	CO MP 16	CO MP 17	CO MP 18
X	40,82	79,54	85,15	85,97	89,6	92,25	97,52	98,75	99,38	99,72	99,81	99,87	99,99	99,99	100	100	100	100
NO ₂	43,91	49,79	53,87	62	63,79	66,35	67,31	68,77	70,94	74,14	76,08	77,14	77,78	95,94	99,49	99,99	100	100

Elaborado por: Autor

Los modelos PLSR capturan la mayor parte de la información de las variables predictoras que es útil para explicar y predecir la variable dependiente, y a su vez el modelo de regresión reduce la dimensión al utilizar menos variables latentes que el número de variables independientes (Zhang, Zhou , & Zhang , 2007).

La matriz de coeficientes de regresión (ver tabla 16) de los modelos PLSR se usan para demostrar la orientación de la relación entre las variables a explicar y las predictoras. (Yan , Wu, & Wang, 2013)

Tabla 16. Coeficientes de regresión del modelo PLSR de dióxido de nitrógeno

Variables	Comp 1	Comp 2	Comp 3	Comp 4	Comp 5	Comp 6	Comp 7	Comp 8	Comp 9	Comp 10	Comp 11	Comp 12	Comp 13	Comp 14	Comp 15	Comp 16	Comp 17	Comp 18
BLUE-TOA	0,02	-0,14	0,21	0,96	1,83	3,33	3,94	4,49	4,67	2,82	0,72	-4,54	-7,24	-135,13	-161,5	-146,2	-144,1	-144,1
GREEN-TOA	-0,07	-0,25	0,04	0,95	1,72	2,92	3,37	3,78	4,29	3,69	6,98	11,85	15,68	119,39	135,2	124,5	123,0	123,1
RED-TOA	0,01	-0,20	-0,15	1,10	1,62	2,11	2,22	2,19	4,56	8,82	11,93	13,31	16,18	104,78	130,3	122,7	120,3	120,2
NIR-TOA	-0,63	-0,84	-0,68	0,80	0,93	0,68	0,43	-0,27	-1,30	-2,29	-2,68	-3,55	-5,85	-83,98	-84,3	-88,8	-88,1	-88,1
SWIR1-TOA	-0,23	-0,49	-0,55	-1,04	-1,66	-2,34	-2,63	-3,01	-4,02	-5,46	-6,92	-5,55	-3,43	59,36	80,6	87,9	90,1	90,1
SWIR2-TOA	0,08	-0,12	-0,25	-1,44	-1,72	-0,94	-0,55	0,37	2,10	5,10	7,12	7,05	5,17	-48,11	-45,9	-51,6	-52,8	-52,8
BLUE-ATM	0,28	0,24	0,79	4,17	5,32	6,82	7,67	9,04	8,94	12,25	11,13	11,59	11,76	34,49	33,4	34,1	34,1	34,1
GREEN-ATM	-0,06	-0,27	-0,63	-2,08	-2,35	-4,15	-4,45	-3,56	-2,49	-1,67	0,65	1,25	1,19	-17,65	-16,3	-16,3	-16,2	-16,2
RED-ATM	0,00	-0,23	-0,38	-1,11	-1,24	-1,84	-2,16	-2,86	-1,78	0,57	1,42	2,25	4,34	80,11	88,2	116,5	117,7	117,7
NIR-ATM	-0,65	-0,88	-0,86	-0,97	-1,31	-2,32	-2,85	-3,84	-5,22	-7,11	-9,40	-11,75	-14,49	-81,92	-100,4	-128,0	-129,2	-129,2
SWIR1-ATM	-0,23	-0,50	-0,66	-2,48	-3,45	-4,62	-5,11	-5,78	-7,51	-9,97	-12,42	-12,14	-10,59	38,17	31,6	30,6	31,6	31,6
SWIR2-ATM	0,08	-0,12	-0,33	-2,66	-3,24	-2,86	-2,62	-1,87	-0,54	1,97	3,88	3,52	1,61	-48,82	-72,2	-73,3	-74,2	-74,2
EVI	-0,62	-0,65	-0,44	-0,46	-0,57	-0,69	-0,71	-0,51	-1,96	-5,68	-10,52	-17,10	-18,79	-5,01	-1,5	-7,6	-9,3	-9,2
MNDWI	0,45	0,41	0,50	-1,93	-2,22	-3,16	-3,52	-4,71	-7,78	-14,13	-18,16	-17,61	-19,82	-14,54	-13,3	-14,1	-14,2	-14,2
MSAVI	-0,66	-0,73	-0,46	1,70	2,09	2,65	2,79	2,94	2,37	1,70	2,89	3,90	2,02	-83,41	-94,8	-92,3	-92,7	-92,7
MSI	0,56	0,62	1,09	6,73	7,38	8,52	9,07	10,24	13,73	16,46	16,94	17,44	16,56	24,24	21,3	23,8	24,2	24,2
NBR	-0,57	-0,57	-0,52	-0,62	-0,37	-0,25	-0,21	0,06	1,86	4,13	3,26	3,93	3,03	-47,07	-95,5	-102,5	-103,1	-103,1
NDBI	0,57	0,58	0,64	1,64	1,19	0,37	0,02	-0,81	-4,53	-10,56	-12,50	-13,45	-12,83	-58,23	-80,8	-88,3	-90,1	-90,2
NDVI	-0,55	-0,53	-0,38	0,83	1,40	3,04	3,76	5,38	7,52	10,04	13,39	18,28	22,88	162,69	189,2	168,2	169,1	169,0
SAVI	-0,61	-0,62	-0,49	0,14	0,18	0,44	0,53	0,94	0,78	0,40	1,93	4,84	6,60	77,15	94,1	150,8	150,9	150,9
PP	0,25	0,52	1,89	0,81	0,20	-0,83	-1,15	-1,42	-0,48	1,60	4,42	5,33	6,20	21,81	25,8	24,6	24,8	24,8
HR	-0,35	-0,38	-0,59	-0,25	-0,45	-0,75	-0,41	-0,91	-1,24	-0,94	3,87	3,75	3,66	37,43	31,1	30,1	30,8	30,8
T	0,36	0,37	0,47	1,87	2,42	3,07	2,81	3,15	2,73	3,10	7,40	7,12	6,72	40,74	33,3	33,5	34,5	34,5

Elaborado por: Autor

Se observa que en la figura 7 no existen datos anómalos en los 3 componentes analizados, ya que por la distribución o patrones de los residuos nos indican que su desviación está dentro de los rangos normales. Además en el gráfico los valores entre paréntesis describen las diferentes variancias de las variables latentes.

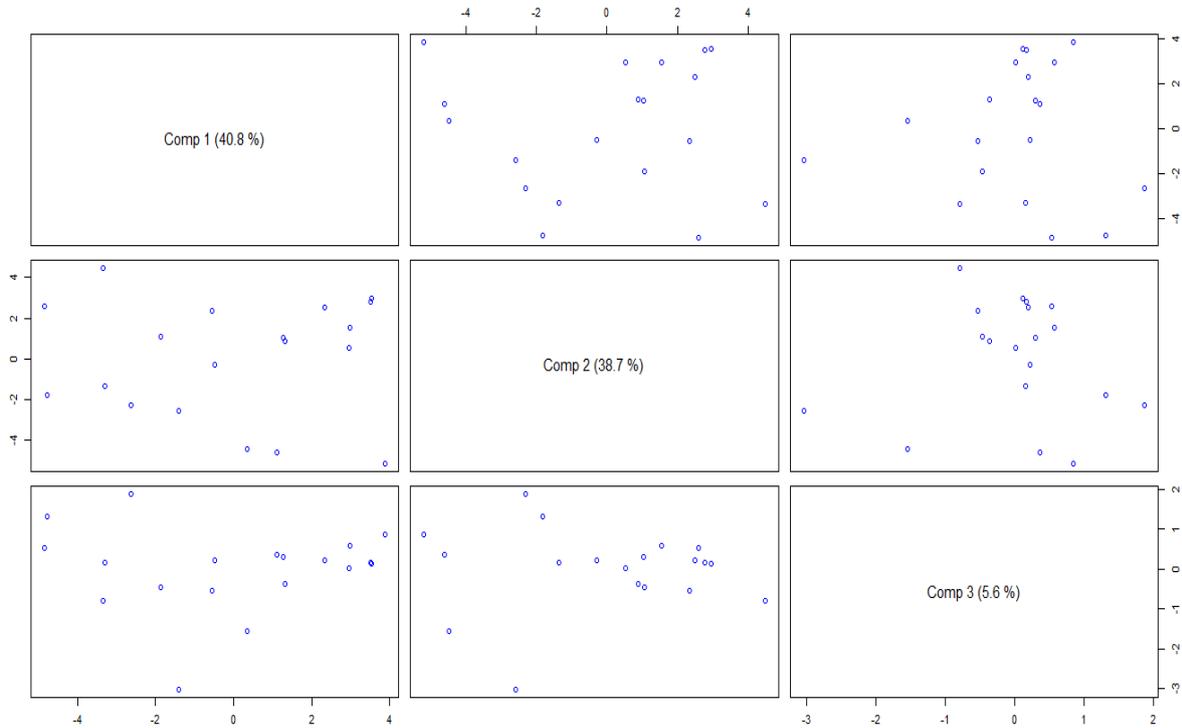


Figura 7. Residuos de 3 componentes del modelo PLSR

Elaborado por: Autor

3.7 Validación

En la validación y elección de los componentes (Jing & Chen , 2016) se estableció que los valores de RMSEP deben ser los más bajos posibles, en contraposición el R_2 deber ser el más alto, pero evitando los sobreajustes del modelo.

3.7.1 RMSEP

En la figura 8 se observa que el error cuadrático medio de predicción que está en función de los componentes. Por lo tanto, en la elección del número óptimo de variables latentes se basó en la visualización del mínimo local en la gráfica para evitar un sobreajuste del modelo PLSR

por esa razón se optó por escoger el componente 13, cuyo valor de RMSEP = 3,99 y representa unidades de error promedio en la predicción de valores (Nguyen & Lee, 2006).

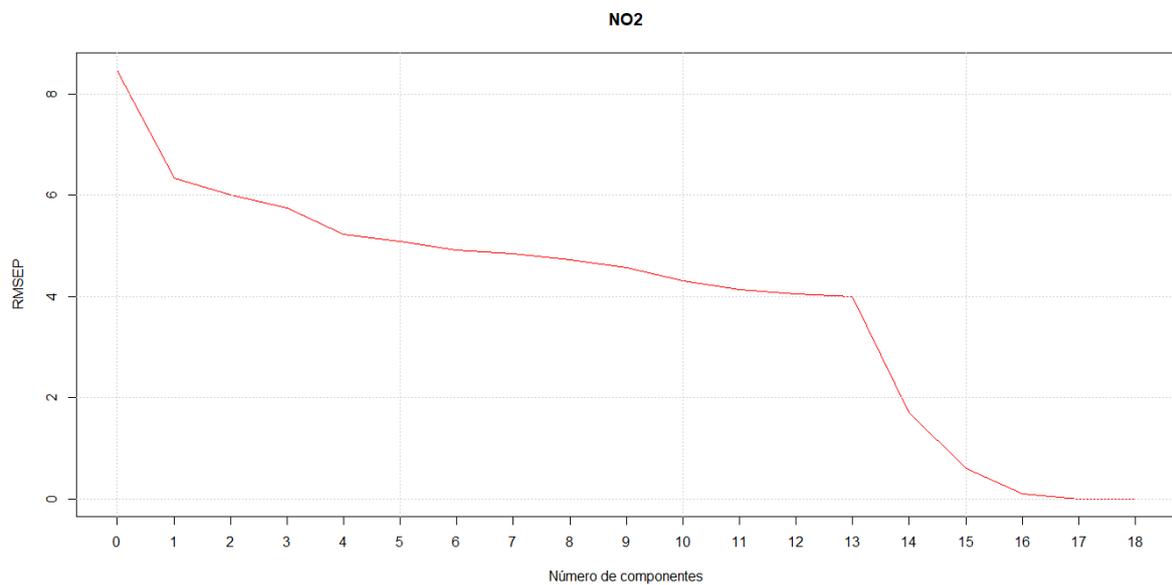


Figura 8. RMSEP del modelo PLSR en función a los 18 componentes

Elaborado por: Autor

En la figura 8 se observa que el PLSR necesita aproximadamente de 13 componentes para expresar la mayor proporción de la variabilidad de las variables predictoras y a explicar.

3.7.2 Coeficiente de determinación

En el figura 9 se observa el porcentaje de variabilidad de la variable a explicar (NO_2) expresado por el modelo (Gallego, 2009), el valor de R^2 para el componente 13 es de 0,78, dicho valor está en un nivel aceptable así como lo establece (Chen & Qi, 2017).

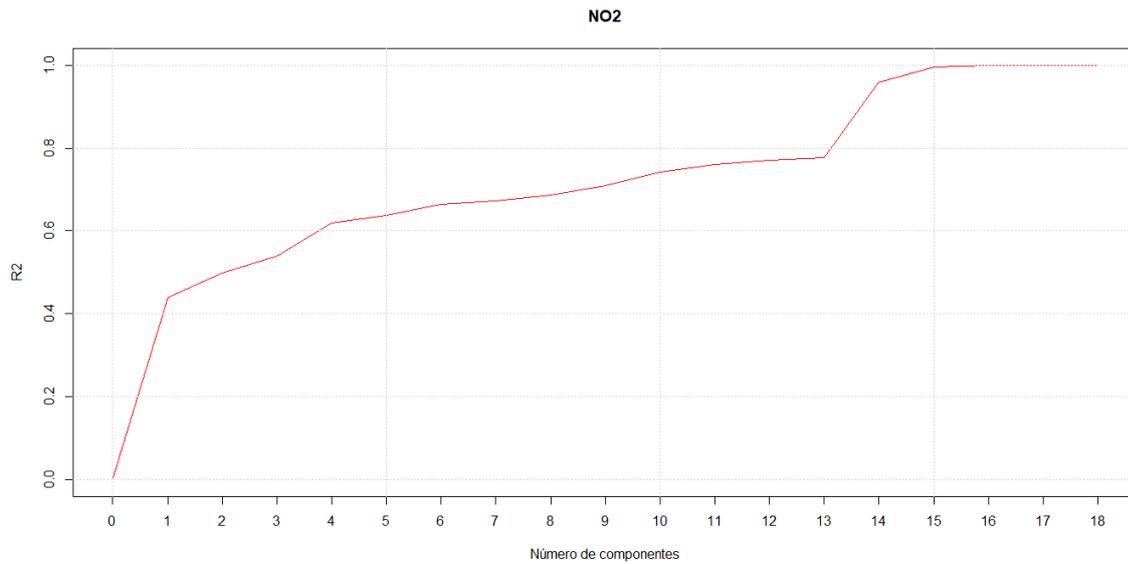


Figura 9. Coeficiente de determinación del modelo PLSR

Elaborado por: Autor

Los valores medidos y predichos se ajustan a una tendencia lineal como se indica en la figura 10. Para generar el grafico se utilizó el RMSEP del componente 13 y los predictores para obtener una visualización de los datos.

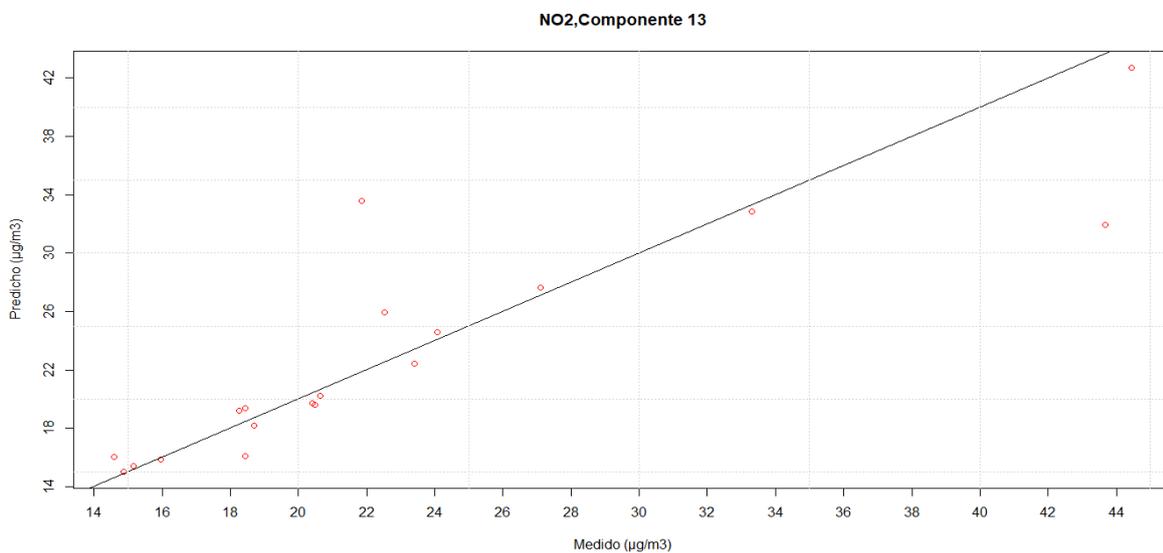


Figura 10. Relación entre los valores medidos y predichos del NO₂

Elaborado por: Autor

En general, los modelos de regresión mínimos cuadrados parciales funcionaron bien en, cuanto se refiere a la combinación de imágenes Landsat y la adición de las variables

meteorológicas para determinar la concentración de NO₂, esto se evidencio en función al RMSEP y R₂.

3.8 Mapa de la concentración de dióxido de nitrógeno de la ciudad de Cuenca

Al analizar la figura 11, se detectó la mayor concentración de NO₂ en las parroquias de Totoracocha, Hermano Miguel, y San Sebastián con valores que van desde 34 a 45 µg/m³, mientras que las concentraciones más bajas se presentaron en Monay y Machángara con valores que no superaban los 15 µg/m³.

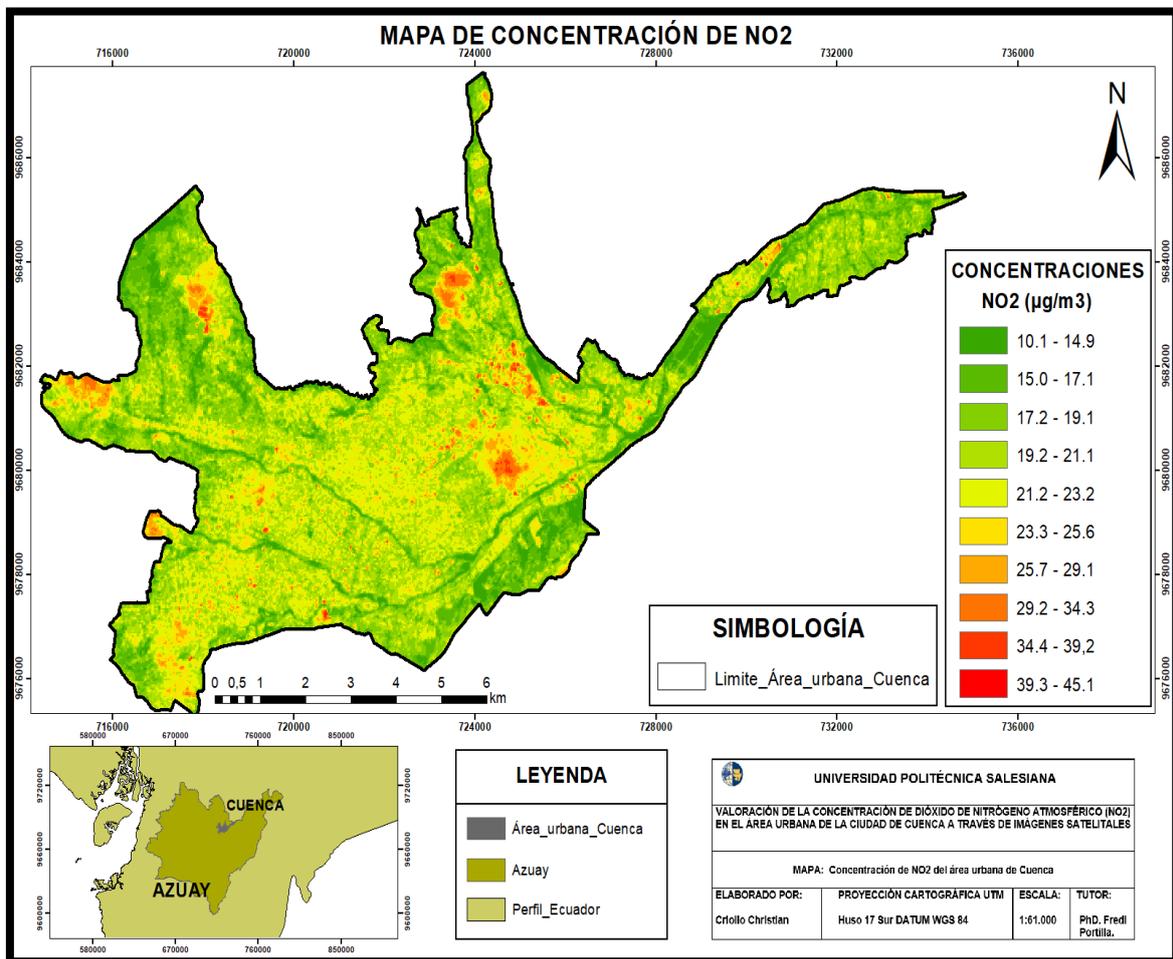


Figura 11. Mapa de la concentración de NO₂ de la ciudad de Cuenca aplicando el modelo PLSR

Elaborado por: Autor

Cabe recalcar que las concentraciones del NO₂ aumentan mientras disminuye la dispersión del contaminante es decir, están influenciados por las condiciones climáticas (velocidad del viento) (Fernández, 2015).

Tabla 17. Comparación de valores reales vs predichos

Puntos monitoreo	Estaciones pasivas	Modelo Regresión
	Concentración SO2 (Real)	Concentración SO2 (Predicho)
EVI	20,42	19,69
MEA	24,08	24,58
ODO	20,65	20,24
CHT	20,48	19,60
TET	27,10	27,66
MUN	21,85	33,58
EIE	23,40	22,41
CRB	15,95	15,86
BAL	18,43	19,37
EIA	18,70	18,21
CCA	22,52	25,94
ECC	18,27	19,22
EHS	14,87	15,01
BCB	44,45	42,71
LAR	33,32	32,82
VEG	43,67	31,95
MAN	15,17	15,40
CEB	18,45	16,08
MIS	14,60	16,04

Elaborado por: Autor

Como se mencionó anteriormente los valores predichos tienen un error de 4 más/menos en la predicción del NO₂ en función a los medidos *in situ* lo que nos indica que los valores no se alejan de los reales como se puede observar en la tabla 17.

3.9 Mapa de nivel de riesgo a la exposición de dióxido de nitrógeno

El mapa de riesgos se elaboró para conocer las zonas vulnerables a la exposición del NO₂ en la ciudad de Cuenca.

La figura 12 se realizó en función a los límites máximos permisibles de la norma ecuatoriana y de la OMS para periodos largos de exposición de NO₂. Como se puede observar en el mapa existen escasas zonas donde las concentraciones superan los 40 µg/m³. Las parroquias urbanas con valores de concentración que sobrepasan lo establecido son: Totoracocha, Machángara, Hermano Miguel, San Sebastián y Yanuncay.

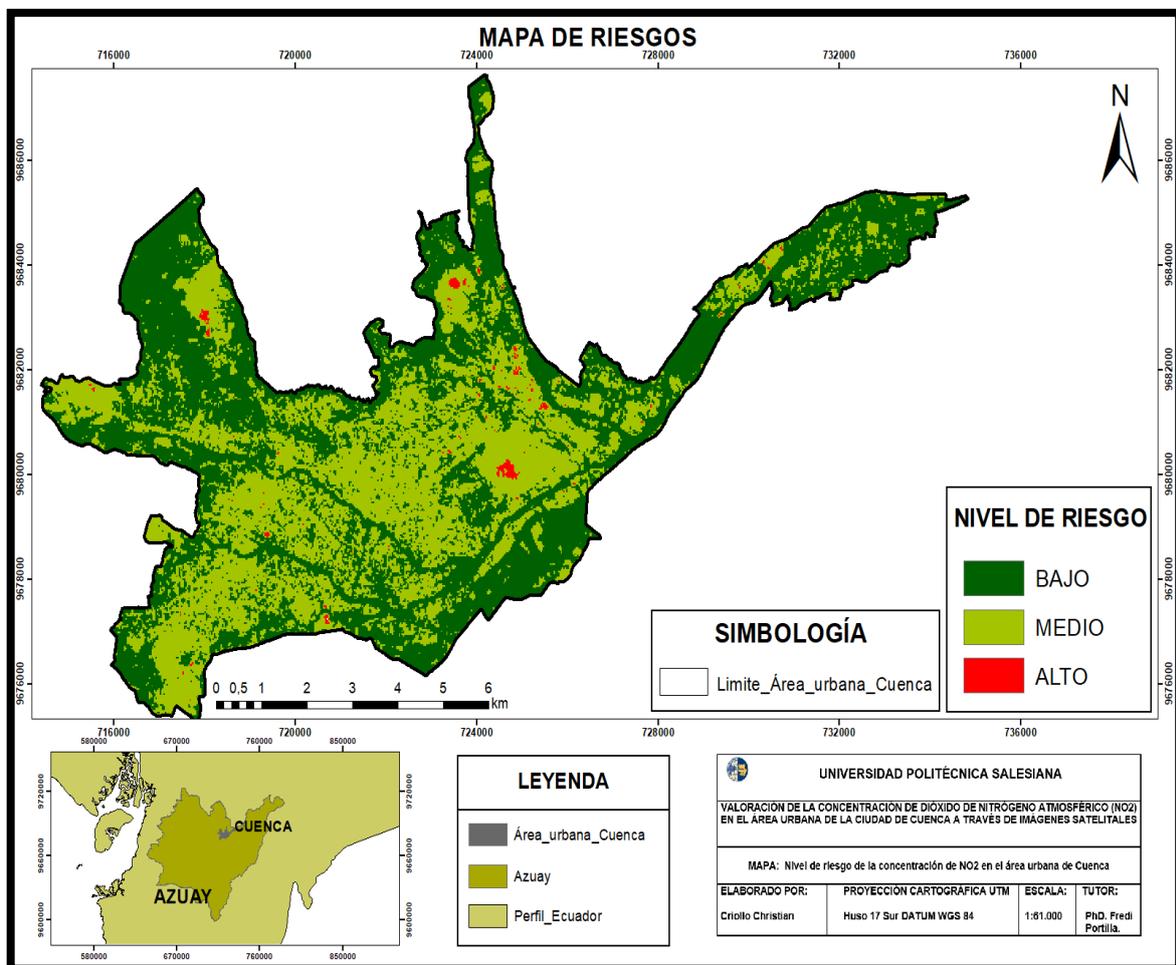


Figura 12. Mapa de riesgos de las concentraciones de NO₂ de periodos largos

Elaborado por: Autor

4. DISCUSIÓN

Los resultados obtenidos nos indican que los modelos PLSR son eficientes, para la evaluación multivariable, debido a que dicha regresión se aplica generalmente a la supervisión de la percepción remota multitemporal. La regresión de mínimos cuadrados junto con la regresión del componente principal (PCR), son procedimientos habituales para el análisis de matrices multivariantes. (Feilhauer, 2010)

Al utilizar la regresión de mínimos cuadrados parciales se disminuye las dimensiones de la matriz de variables predictoras, y garantiza la selección de variables que puedan aportar la mayor proporción de variabilidad de las características de la concentración de NO₂ (Yongua et al., 2008).

La ciudad de Cuenca cuenta con 19 estaciones de monitoreo pasivo de NO₂, que es un limitante en el estudio realizado debido a que no se tiene datos continuos de concentraciones por ese motivo se llevó a cabo un promedio de los datos recopilados. Otro limitante es la cantidad de información satelital del sensor Landsat de los periodos 2014, 2015, 2016 por dicho motivo se combinó las imágenes satelitales Landsat 7 y 8 para recopilar mayor información digital.

Existen varias investigaciones que comparan los datos de Landsat OLI 8 con los datos de Landsat ETM+ 7 utilizando información a cielo despejado para iguales ubicaciones y utilizando los datos adquiridos con varios días de discrepancia (Flood, 2014); (Li, Jiang, & Feng, 2014). Según (Vogelmann et al., 2016) indica que la variabilidad de banda por banda en la percepción remota es mayor en las regiones de longitud de onda más corta que en las longitudes de onda más largas, esto se debe a la diferencia de ocho días para el contraste de Landsat 7 vs 8. El estudio realizado por (Flood, 2014), determinó que la diferencia de reflectancia en el tope de la atmósfera, entre los dos sensores Landsat es de

aproximadamente 6 % y la diferencia de reflectancia superficial es de aproximadamente 2 %. Además se analizó el índice espectral (NDVI) que se vio afectado en alrededor del 5%, en promedio. Sobre la base de las consideraciones anteriores, (Li, Jiang, & Feng, 2014) concluye que, los dos sensores son lo suficientemente similares como para que puedan usarse combinados sin mayores inconvenientes para estudios multitemporales.

El estudio realizado por (Burgos & Copo, 2017) para la determinación de contaminantes atmosféricos mediante mínimos cuadrados parciales obtuvo mejores resultados ya que se aplicó la información *in situ* de las estaciones automáticas de monitoreo.

La variable latente o componente 13 se estableció debido al número óptimo de componentes utilizados para la regresión, para dicho procedimiento se comparó la raíz cuadrada del error cuadrático medio de predicción de validación cruzada (RMSEP) de las predicciones generadas con diferentes componentes (Udelhoven , Emmerling , & Jarmer , 2003).

Los resultados de las concentraciones del NO₂ en Cuenca, presenta que las zonas de concentraciones media del contaminante fueron Centro Histórico y las parroquias Hermano Miguel y Totoracocha, esto se debe a que son lugares con alto tráfico vehicular además de la presencia del aeropuerto, cabe agregar que la dispersión genera una menor concentración del NO₂ (Fernández, 2015).

5. CONCLUSIONES

1. Para el periodo de estudio se recolectaron 21 imágenes satelitales obtenidas de los 2 sensores de los cuales, se consideró un total de 8 imágenes satelitales del año 2016, de estas 5 fueron de Landsat OLI 8 y 3 de Landsat ETM+ 7. Las mismas se eligieron en función al mayor número de imágenes Landsat en un año y por el menor porcentaje de nubosidad dentro del área de estudio.
2. La regresión de mínimos cuadrados parciales se aplicó para la matriz de 23 variables predictoras y 1 variable a explicar (NO_2), además de 19 observaciones (puntos de monitoreo). El modelo con el componente 13 explican el 99,99 % y 77,78% de la varianza de las variables predictoras y de la explicativa (NO_2) respectivamente, esto nos indica que los resultados obtenidos son confiables y abarcan un gran porcentaje de variabilidad de los datos.
3. El modelo PLSR se analizó con el $\text{RMSEP} = 3,99$ en la predicción de los datos originales, y con un coeficiente de determinación ($R^2 = 0,78$), estos resultados nos indican que se obtuvieron valores significativos para predecir el NO_2 .
4. Se generó el mapa de las concentraciones de NO_2 de la ciudad de Cuenca que se estimó con los coeficientes positivos de regresión del modelo PLSR y las variables predictoras, en el cual la mayor contaminación se dio en las parroquias de Totoracocha y Hermano Miguel, las que sobrepasan la norma ecuatoriana de $40 \mu\text{g}/\text{m}^3$.
5. Finalmente se observa que la concentración de dióxido de nitrógeno de $20 - 39 \mu\text{g}/\text{m}^3$ esta presenta en 44 % del área, mientras que la concentración de $40 - 45 \mu\text{g}/\text{m}^3$ es la de menor porcentaje de área con tan solo 0,5 % en la ciudad de Cuenca.

6. RECOMENDACIONES

Los satélites Landsat 7 y 8 han generado resultados adecuados, tomando en consideración que la información digital se obtiene en forma gratuita , además abarca grandes extensiones de área en una sola escena, con lo cual se reduce costes al momento de aplicar investigaciones sobre contaminantes atmosféricos. Adicionalmente se puede usar otros sensores gratuitos como Sentinel, Aster y Modis para contrastar investigaciones multitemporales.

Con la información resultante se puede comparar y validar las mediciones de las concentraciones de los diferentes contaminantes atmosféricos, además se pueden identificar zonas de mayor concentración, es por esto que los modelos PLSR aplicado a estudios multitemporales pueden ser usados por las instituciones gubernamentales para la toma de decisiones sobre la contaminación de atmosférica.

7. BIBLIOGRAFÍA

- Abad, L. (2016). *Estimación de la concentración de material particulado menor a 10 micras a través de sensores remotos en el área urbana de la ciudad de Cuenca*. Cuenca.
- Abdi , H., & Williams, L. (2013). *Partial Least Squares Methods: Partial Least Squares Correlation and Partial Least Square Regression*. Colorado .
- Abdulrahman , A. (2010). *Remote Sensing* . Iraq .
- Adole, T., Dash, J., & Atkinson , P. (2018). Characterising the land surface phenology of Africa using 500m MODIS EVI. *Applied Geography*, 187-199.
- Aggarwal, S. (2003). *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology* . India .
- Aguas, C. (2016). *Estimación de biomasa aérea forestal en bosque de robledales del altiplano norte de Antioquia, utilizando teledetección*. Medellín.
- Alciatui , C., Escobar , M., De la Cruz, C., & Rincón , C. (2003). Partial least squares (PLS) regression and its application to coal analysis . *Técnica de Ingeniería Universitaria de Zulia* , 197-204.
- Ariza, A. (2013). *Descripción y corrección de productos Landsat 8 (LCDM)*. Bogotá .
- Arizaga, A. (2013). *Descripción y corrección de productos LANDSAT 8 (LCDM)*. Bogotá.
- Aulia, M., Setiawan, Y., & Fatikhunnada, A. (2016). Drought Detection of West Java's Paddy Field Using MODIS EVI Satellite Images (Case Study: Rancaekek and Rancaekek Wetan). *Procedia Environmental Sciences* , 646-653.
- Belletti , S., Godino, M. E., & Blesio, G. (2016). *Ondas Electromagnéticas: Física* . Bogotá .
- Burgos, M., & Copo, K. (2017). *Estimación de la concentración de ozono troposférico (O3) mediante análisis geoespacial de imágenes satelitales y mínimos cuadrados parciales, para las parroquias urbanas del cantón Quito*. Quito.
- Butler, M., Mouchot, M., & Barale, V. (1988). *The application of remote sensing technology to marine fisheries: an introductory manual*. Canada.
- Buzzi, M., Rueter, B., & Ghermandi, L. (2017). Múltiples índices espectrales para predecir la variabilidad de atributos estructurales y funcionales en zonas áridas. *Ecología Austral*, 55-62 .
- Calle, J., & Tinoco, Ó. (2018). Obtención de ACS con energía solar en el cantón Cuenca y análisis de la contaminación ambiental. *Ingenius*, 89-101.
- Campbell, M., & Wynne, R. (2011). *Introduction to Remote Sensing*. . New York.
- Cango, P., & Carchipulla, N. (2010). *Valoración económica del bien ambiental: calidad del aire en la ciudad de Cuenca, 2010*. Cuenca.
- Casasola, F. (2016). *Implementación de herramientas de Teledetección e Inteligencia Artificial para la optimización de los recursos del Ejército Argentino en situaciones de emergencias volcánicas*. Córdoba.

- Centro de Ecología Aplicada. (2014). *Diagnóstico de la condición trófica de cuerpos lacustres utilizando nuevas herramientas tecnológicas*. Santiago.
- Cervantes , E. R. (2014). *Clasificación de imágenes satelitales mediante el uso de Memorias Asociativas*. México.
- Chavez , P. (1988). An Improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote sensing of environment* , 459-479.
- Chen, P., & Qi, J. (2017). A comparison of two adaptive Multivariate Analysis Methods (PLSR and ANN) for Winter Wheat Yield Forecasting Using Landsat-8 OLI Images. *Advances in space research*.
- Chunyang , H., Peijun , S., Dingyong , X., & Yuanyuan , Z. (2010). Improving the normalized difference built-up index to map urban built-up areas using a semiautomatic segmentation approach. *Remote Sensing Letters*, 37-41.
- Cohen , A., Braver, M., Burnett, R., Anderson, R., & Frostad, J. (2017). Estimates and 25-year trends of the global burden of disease attributable to ambient air pollution: an analysis of data from the Global Burden of Diseases Study 2015. *The Lancet*, 1907-1918.
- Curran, P., & Hay, A. (1986). The importance of measurement error for certain procedures in remote sensing at optical wavelengths. *Photogrammetric Engineering and remote sensing* , 229-241.
- Diario El Tiempo. (10 de Julio de 2016). Niveles de contaminación tienden a crecer. *El tiempo*.
- Díez, J. (2018). *Código de Atmósfera y Cambio Climático* . Madrid.
- Ding, H., Shi, J., & Wang, Y. (2015). An improved Dark-Object subtraction method for Atmospheric Correction of Landsat 8. *Remote Sensing Image Processing* .
- Dube, T., & Mutanga, O. (2015). Evaluation the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa . *ISPRS Journal of Photogrammetry and Remote Sensig* , 36-46.
- Escuin , S., Navarro , R., & Fernández , P. (2013). Fire severity assessment by using NBR (Normalized Burn Ratio) and NDVI (Normalized Difference Vegetation Index) derived from LANDSAT TM/ETM images . *International Journal of Remote Sensing* , 1053-1073.
- Esquivel, E., & Cuba, D. (2006). Contaminación del aire interior en un proyecto de viviendas con climatización centralizada. *Scielo* .
- Feilhauer, H. A. (2010). Brightness-normalized partial least squares regression. *Journal of Quantitative*, 1947-1957.
- Fernández, L. (2015). *El papel de los óxidos de nitrógeno en el Cambio Climático. Efectos sobre la salud* . Madrid.
- Flood, N. (2014). Continuity of Reflectance Data between Landsat-7 ETM+ and Landsat-8 OLI, for Both Top-of-Atmosphere and Surface Reflectance: A study in the Australian Landscape. *Remote Sensing* , 7952-7970.
- FORMAGRO. (06 de 12 de 2015). *FORMAGRO*. Obtenido de FORMAGRO: <http://www.formagro.com/recursos/descargas/Seguimiento-de-cultivo-FORMAGRO-SRL.pdf>
- Frank, N. (2017). *Teledetección espacial, Landsat, sentinel 2, ASTER L1T Y MODIS* . Perú .

- Gallego, Á. (2009). *Instrumento portátil para medición de compuestos fenólicos en vino tinto usando espectroscopía Raman*. Santiago de Chile.
- García, D., & Barrera, R. A. (2015). *Procesamiento, interpretación y análisis de imágenes satelitales en la banda de los 400 a 700 nanómetros para aplicaciones de percepción remota*. México.
- Gilbert, N., Goldberg, M., Brook, J., & Jerrett, M. (2007). The influence of highway traffic on ambient nitrogen dioxide concentrations beyond the immediate vicinity of highways. *Atmospheric Environment*, 2670-2673.
- Gitelson, A., Kaufman, Y., & Merzlyak, M. (1996). Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS. *Remote Sensing of Environment*, 289-298.
- Gontia, N., & Tiwari, K. (2010). Estimation of crop coefficient and evapotranspiration of wheat (*Triticum aestivum*) in an irrigation command using remote sensing and GIS. *Water Resources Management*, 1399-1414.
- Gonzaga, C. (2014). *Aplicación de índices de vegetación derivados de imágenes satelitales Landsat 7 ETM+ y ASTER para la caracterización de la cobertura vegetal en la Zona Centro de la Provincia de Loja, Ecuador*. Loja.
- González, C., Gómez, C., Rojas, N., Acevedo, H., & Aristizábal, B. (2017). Relative impact of on-road vehicular and point-source industrial emissions of air pollutants in a medium-sized Andean city. *Atmospheric Environment*, 279-289.
- González, M. (2016). *Análisis espectral de sólidos suspendidos en aguas continentales con presencia de actividades mineras: caso de estudio río Sipí, pacífico colombiano*. Bogotá.
- Hameed, S., & Hasan, G. (2014). Estimation of PM10 Concentration using Ground Measurements and Landsat 8 OLI Satellite Image. *Geophysics & Remote Sensing*, 1-6.
- He, T., Liang, S., Wang, D., Cao, Y., & Gao, F. (2018). Evaluating land surface albedo estimation from Landsat MSS, TM, ETM+, and OLI data based on the unified direct estimation approach. *Remote Sensing of Environment*, 181-196.
- Hernández, P., González, A., Arbelo, A., & Nuñez, L. (2009). Cartografiado de áreas quemadas con imágenes MODIS y ASTER. *Teledetección: Agua y desarrollo sostenible*, 277-280.
- Holden, C., & Woodcock, C. (2016). An analysis of Landsat 7 and Landsat 8 underflight data and the implications for time series investigations. *Remote Sensing of Environment*, 16-36.
- Homer, C., Dewitz, J., Fry, J., & Coan, M. (2007). Completion of the 2001 National Land Cover Database for the conterminous United States. *Photogrammetric Engineering and Remote Sensing*, 337-341.
- Huete, A. (1988). A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 295-309.
- Huete, A., Didan, K., Miura, T., Rodriguez, E., & Gao, X. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 195-213.
- INER, I. N. (2014). *Energía eólica y solar*.
- Instituto Nacional de Estadística y Geografía. (2014). *Imágenes de satélite: Elementos de percepción remota*.

- Irisarri , G., Oesterheld, M., Paruelo , J., & Texeira, M. (2012). Patterns and controls of above-ground net primary production in meadows of Patagonia. A remote sensing approach. *Journal of Vegetation Science* , 114-126.
- Irons, J., Taylor, M., & Rocchio, L. (10 de July de 2018). NASA . Obtenido de Landsat Science : <https://landsat.gsfc.nasa.gov/landsat-7/>
- Jaikumar , R., Nagendra , S., & Sivanandan, R. (2017). Modal analysis of real-time, real world vehicular exhaust emissions under heterogeneous traffic conditions . *Transportation Research Part D*, 397-409.
- Jiang, Z., Huete , A., & Didan , K. (2008). Development of a two-band enhanced vegetation index without a blue band . *Remote Sensing of Environment*, 3833-3845.
- Jing , Q., & Chen , P. (2016). A comparison of Two adaptive multivariate analysis methods (PLSR and ANN) for winter wheat yield forecasting using Landsat-8 OLI Images . *Advances in space research* .
- Jordan , C. (1969). Derivation of Leaf-Area Index from Quality of light on the Forest Floor. *Ecological Society of America* , 663-666.
- Kumar, N. (2013). *Remote Sensing: Introduction and basic concepts*. Bangkok.
- Li, P., Jiang, L., & Feng, Z. (2014). Cross-Comparison of Vegetation Indices Derived from Landsat-7 Enhanced Thematic Mapper Plus (ETM+) and Landsat-8 Operational Land Imager (OLI) Sensors. *Remote Sensing* , 310-129.
- Liang, S., Li, X., & Wang, J. (2012). A Systematic View of Remote Sensing . *Advanced Remote Sensing*, 1-31.
- López, T., & Pacheco, A. (2015). *Efectos de la contaminación atmosférica en la salud de las personas en la Ciudad de Cuenca* . Cuenca .
- Mai, T. (7 de Agosto de 2017). NASA. Obtenido de NASA: https://www.nasa.gov/directorates/heo/scan/communications/outreach/funfacts/txt_passive_active.html
- Manzo, L., & López, J. (2013). Detección de áreas quemadas en el sureste de México, utilizando índice pre y post-incendio NBR y BAI, derivados de compuestos MODIS. *Revista Iinternacional de Ciencia y Tecnología de la Información Geográfica* , 66-83.
- Martínez, J. R. (2003). *Física y Química. Volumen II. Física II*. Murcia: Editorial MAD, S.L.
- Ministerio del Ambiente. (2010). *Plan Nacional de la Calidad de Aire*. Quito.
- Mogrovejo, F. (2015). *Evaluación de las tendencias de calidad del aire en la zona metropolitana del Valle de Toluca durante los años 2000 – 2013*. Cuenca.
- Municipalidad de Cuenca . (2008). *Informe de la calidad de aire de Cuenca* . Cuenca.
- Municipalidad de Cuenca . (2016). *Informe de la calidad del aire de Cuenca* . Cuenca.
- Municipalidad de Cuenca. (2011). *Informe de Calidad de Aire* . Cuenca.

- Mustafa , T., & Hassoon , I. (2017). Using water indices (NDWI, MNDWI, NDMI, WRI and AWEI) to detect physical and chemical parameters by apply remote sensing and GIS techniques . *International journal of research-granthaalayah* , 2394-3629.
- NASA. (5 de Julio de 2011). *Landsat 7 Science Data Users Handbook Landsat Project Science Office at NASA Goddard Space Flight Center in Greenbelt*. USA. Obtenido de NASA.
- Nguyen , H., & Lee, B. (2006). Assessment of rice leaf growth and nitrogen status by hyperspectral canopy reflectance and partial least square regression . *European Journal of Agronomy*, 349-356.
- Palacios, J., Bisher , Y., & Cabrera , F. (2009). *Aplicación de la Radiometría Multiespectral para detectar estres hidrico en el cultivo de maíz (Zea mayz L.) en el Sur de Sonora México*. . México: UNISON-INIFAP.
- PDOT. (2015). *Plan de desarrollo y ordenamiento territorial del cantón Cuenca*. Cuenca .
- Peng, L., Zhiming, F., & Chiwei, X. (2018). Detecting and mapping annual newly-burned plots (NBP) of swiddening using historical Landsat data in Montane Mainland Southeast Asia (MMSEA) during 1988-2016. *Journal of geographical sciences*, 1307-1328.
- Prieto, M., Mancilla, P., & Astudillo, P. (2007). Exceso de morbilidad respiratoria en niños y adultos mayores en una comuna de Santiago con alta contaminación atmosférica por partículas. *Scielo*, 221-228.
- Qi , J., Chehbouni , A., Huete , A., Kerr, H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote sens. Environ* , 119-126.
- Quiroz, M. (2011). *Tecnologías de la información geografica (TIG) Cartografía. fotointerpretacion, teledetección y SIG*. México: Ediciones Salamanca.
- Regueira , Y., Schlatter, S., & Diaz, G. (2009). Determinación de la concentración de dióxido de nitrógeno en la atmosfera de Ciudad de La Habana mediante . *CENIC Ciencias Químicas*, 23-25.
- Reuter, F. (2009). *Plataformas orbitales y sensores*. Chile.
- Richards, J., & Jia, X. (2006). *Remote Sensing Digital Image Analysis: An Introduction*. Germany.
- Romero, E., Paz, F., Palacios , E., & Bolaños, M. (2009). Diseño de un índice espectral de la vegetación desde una perspectiva conjunta de los patrones exponenciales y lineales del crecimiento. *Agrociencia*, 1405-3195.
- Rosales, A., Martínez , F., & Martínez , E. (2010). Filtro de mediana y filtro de vector de mediana aplicados a imágenes multicanales para la supresión de ruido impulsivo. *Vigésima primera reunión de otoño de comunicaciones, computación, electrónica y exposición industrial*. Acapulco.
- Rouse , J., & Hass, R. (1973). Monitoring vegetation systems in the great plains with erts. *Remote Sensing Center*, 309-317.
- Rouse, J., Haas, R., & Schell, J. (1973). Monitoring vegetation systems in the great plains with erts. *Remote Sensing Center*, 309-317.

- Roy, D., Jin, Y., Lewis, P., & Justice, C. (2005). Prototyping a global algorithm for systematic fire-affected area mapping using MODIS time series data. *Remote Sensing of Environment*, 137-162.
- Rugel, E., Henderson, S., Carpiano, R., & Brauer, M. (2017). Beyond the Normalized Difference Vegetation Index (NDVI): Developing a Natural Space Index for population-level health research. *Environmental Research*, 474-483.
- Running, S., Thornton, P., Nemani, R., & Glassy, J. (2000). Global Terrestrial Gross and Net Primary Productivity from the Earth Observing System. *Methods in ecosystem science*, 44-57.
- Saraswat, I., Mishra, R., & Kumar, A. (2017). Estimation of PM10 concentration from Landsat 8 OLI satellite imagery over Delhi, India. *Remote Sensing Applications: Society and Environment*, 251-257.
- SAS. (2000). *SAS Users Guide, Version 8*. North Carolina.
- Schott, J., Salvaggio, C., & Volchok, W. (1988). Radiometric scene normalization using pseudoinvariant features. *Remote Sensing of Environment*, 1-14.
- Sendra, V., Camacho, F., Sánchez, J., & Muñoz, J. (2015). Método para la corrección atmosférica de imágenes Landsat. *Teledetección: Humedales y Espacios Protegidos*, 484-487.
- Silleos, G., Gitas, I., Alexandridis, T., & Perakis, K. (2006). Vegetation indices: Advances made in Biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International*, 21-28.
- Sobrino, J., Raissouni, N., & Li, Z. (2001). A comparative study of Land Surface Emissivity retrieval from NOAA Data. *Remote Sensing of Environment*, 256-266.
- Soria, M. V., & Matar de Saquis, M. A. (2016). *Nociones sobre Teledetección*. Argentina.
- Teillet, P., Barker, J., Markham, B., & Irish, R. (2001). Radiometric cross-calibration of the Landsat-7 ETM+ and Landsat-5 TM sensors based on tandem data sets. *Remote Sensing of Environment*, 39-54.
- Testa, S., Soudani, K., Boschetti, L., & Borgogno, E. (2018). MODIS-derived EVI, NDVI, and WDRVI time series to estimate phenological metrics in French deciduous forests. *International Journal of Applied Earth Observation and Geoinformation*, 132-144.
- Toro, V., Ramírez, J., Quiceno, R., & Zuluaga, C. (2001). *Cálculo de la emisión vehicular de contaminantes atmosféricos en la Ciudad de Medellín mediante factores de emisión Corinair*. Medellín.
- Udelhoven, T., Emmerling, C., & Jarmer, T. (2003). Quantitative analysis of soil chemical properties with diffuse reflectance spectrometry and partial least-square regression: A feasibility study. *Plant and Soil*, 319-329.
- USGS. (2016). *LANDSAT 8 (L8) DATA USERS HANDBOOK*. Department of the Interior U.S. Geological Survey. Version 2.0. USA. Obtenido de USGS.
- USGS. (2017). *Landsat surface reflectance-derived spectral indices*. California.
- Valdéz, D. (2010). Regresión por mínimos cuadrados parciales. *Scielo*.
- Vega, L. (2012). *Gap Fill for Landsat 7 images-A correction of SLC-off*.

- Vogelmann, J., Gallant, A., Shi, H., & Zhu, Z. (2016). Perspectives on monitoring gradual change across the continuity of Landsat sensors using time-series data. *Remote Sensing of Environment*, 1-13.
- Wei, X., Gu, X., Meng, Q., & Zhan, Y. (2017). Cross-comparative analysis of GF-1 wide field view and LANDSAT-7 enhanced thematic mapper plus data. *Journal of Applied Spectroscopy*, 829-836.
- Wolter, P., Townsend, P., & Sturtevant, B. (2008). Remote sensing of the distribution and abundance of host species for spruce budworm in Northern Minnesota and Ontario. *Remote Sensing of Environment*, 3971-3982.
- Xie, Q., Huang, W., Dash, J., & Song, X. (2015). Evaluating the potential of vegetation indices for winter wheat LAI estimation under different fertilization and water conditions. *Advances in Space Research*, 2365-2373.
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 3025-3033.
- Xu, H. (2008). A new index for delineating built-up land features in satellite imagery. *International Journal of Remote Sensing*, 4269-4276.
- Yan, F., Wu, B., & Wang, Y. (2013). Estimating aboveground biomass in Mu Us Sandy Land using Landsat spectral derived vegetation indices over the past 30 years. *Journal of Arid Land*, 521-530.
- Yonghua, Q., Siong, J., & Xudong, L. (2008). A partial least square regression method to quantitatively retrieve soil salinity using hyper-spectral reflectance data. 1-9.
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *Remote Sensing*, 583-594.
- Zhang, Y., Zhou, C., & Zhang, Y. (2007). A partial least-squares regression approach to land use studies in the Suzhou-Wuxi-Changzhou region. *Journal of Geographical Sciences*, 234-244.
- Zhu, Z., & Reed, B. (2012). *Baseline and projected future carbon storage and greenhouse-gas fluxes in ecosystems of the western united states*. EEUU.

8. ANEXOS

Anexo 1. Fórmulas utilizadas para la corrección atmosférica de Landsat 8

Conversión a radiancia en el techo de la atmósfera (TOA)

Los datos de las bandas del sensor TIRS y OLI están derivados en 16 bits en formato no cifrado y pueden ser re escalados a los valores de reflectancia y/ o radiancia en el techo de la atmósfera TOA, usando para ello los coeficientes radiométricos provistos en el archivo de *metadata* MTL.txt, tal y como se describe a continuación (Ariza, 2013)

$$L_{\lambda} = M_L Q_{cal} + A_L$$

Donde:

L_{λ} = Es el valor de radiancia espectral en el techo de la atmósfera (TOA) medida en valores de (Watts/m²*srad* μm)

M_L = Factor multiplicativo de escalado específico obtenido del *metadata* (RADIANCE_MULT_BAND_x, donde x es el número de banda)

A_L = Factor aditivo de escalado específico obtenido del *metadata* (RADIANCE_MULT_BAND_x, donde x es el número de banda)

Q_{cal} = Producto estándar cuantificado y calibrado por valores de pixel (DN). Este valor se refiere a cada una de las bandas de la imagen.

$$p\lambda' = M_p Q_{cal} + A_p$$

Donde:

$p\lambda'$ = Es el valor de reflectancia planetaria, sin corrección por ángulo solar.

M_p = Es el factor multiplicativo de escalado específico por banda obtenido del *metadata* (REFLECTANCE_MULT_BAND_x, donde x es el número de la banda).

A_p = Es el factor aditivo de escalado específico por banda obtenido del *metadato* (REFLECTANCE_ADD_BAND_x, donde x es el número de la banda).

Q_{cal} = Es el producto estándar cuantificado y calibrado para valores de pixel.

Corrección atmosférica DOS1 de la reflectancia superficial

Es importante mencionar que la exactitud de las técnicas basadas en imagen es generalmente menor que las correcciones basadas en medidas físicas, pero son muy útiles cuando no están disponibles mediciones atmosféricas que pueden mejorar la estimación de la reflectancia de la superficie terrestre (Frank, 2017).

El efecto bruma es dado por (Sobrino, Raissouni , & Li, 2001).

$$L_p = L_{min} - L_{DO1\%}$$

L_{min} = Radiancia que corresponde a un valor digital para el cual la suma de todos los pixeles con valores digitales menores o iguales a este valor es igual al 0.01% de todos los píxeles de la imagen considerada (Sobrino, Raissouni , & Li, 2001) por lo tanto, la radiancia obtenida con este valor de conteo digital (DN_{min}).

$L_{DO1\%}$ = Radiancia del objeto oscuro, con un valor asumido de reflectancia de 0.01

En particular para imágenes Landsat:

$$L_{min} = ML * ND_{min} + AL$$

Donde:

ML = Factor multiplicativo de reescalamiento específico de la banda, proveniente de los *metadatos* (RADIANCE_MULT_BAND_x, donde x es el número de banda).

AL = Factor aditivo de reescalamiento específico de la banda, proveniente de los *metadatos*

($RADIANCE_MULT_BAND_x$, donde x es el número de banda).

ND_{min} = Valor digital mínimo.

La radiancia de objeto oscuro es dada por (Sobrino, Raissouni, & Li, 2001)

$$L_{DO1\%} = \frac{0.01 * [(ESUN_{\lambda} * SEN_{(\theta SE)} * T_z) + E_{doun}] * T_v}{\pi * d^2}$$

Por lo tanto, el efecto bruma es:

$$L_p = L * ND_{min} + AL - \frac{0.01 * [(ESUN_{\lambda} * SEN_{(\theta SE)} * T_z) + E_{doun}] * T_v}{\pi * d^2}$$

La técnica DOS1 hace las siguientes suposiciones (Frank, 2017).

Donde:

$$T_v = 1$$

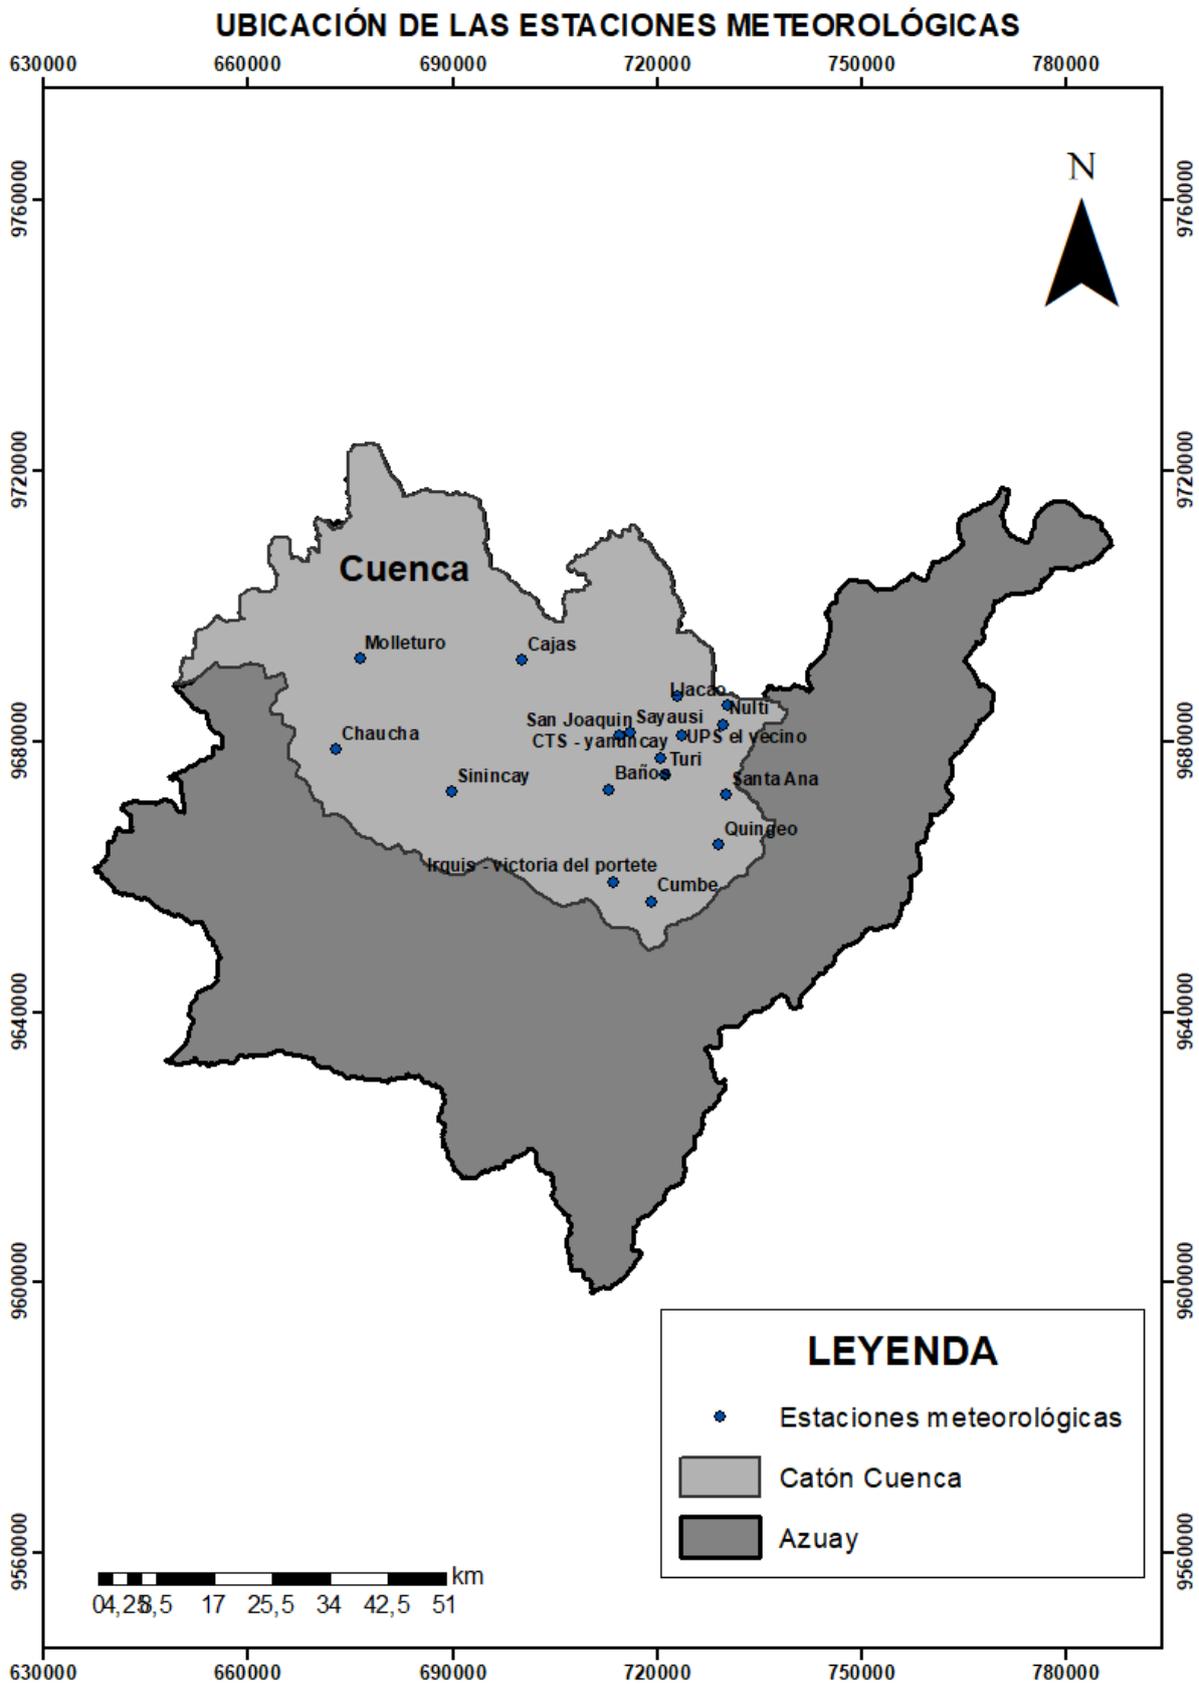
$$T_z = 1$$

$$E_{doun} = 0$$

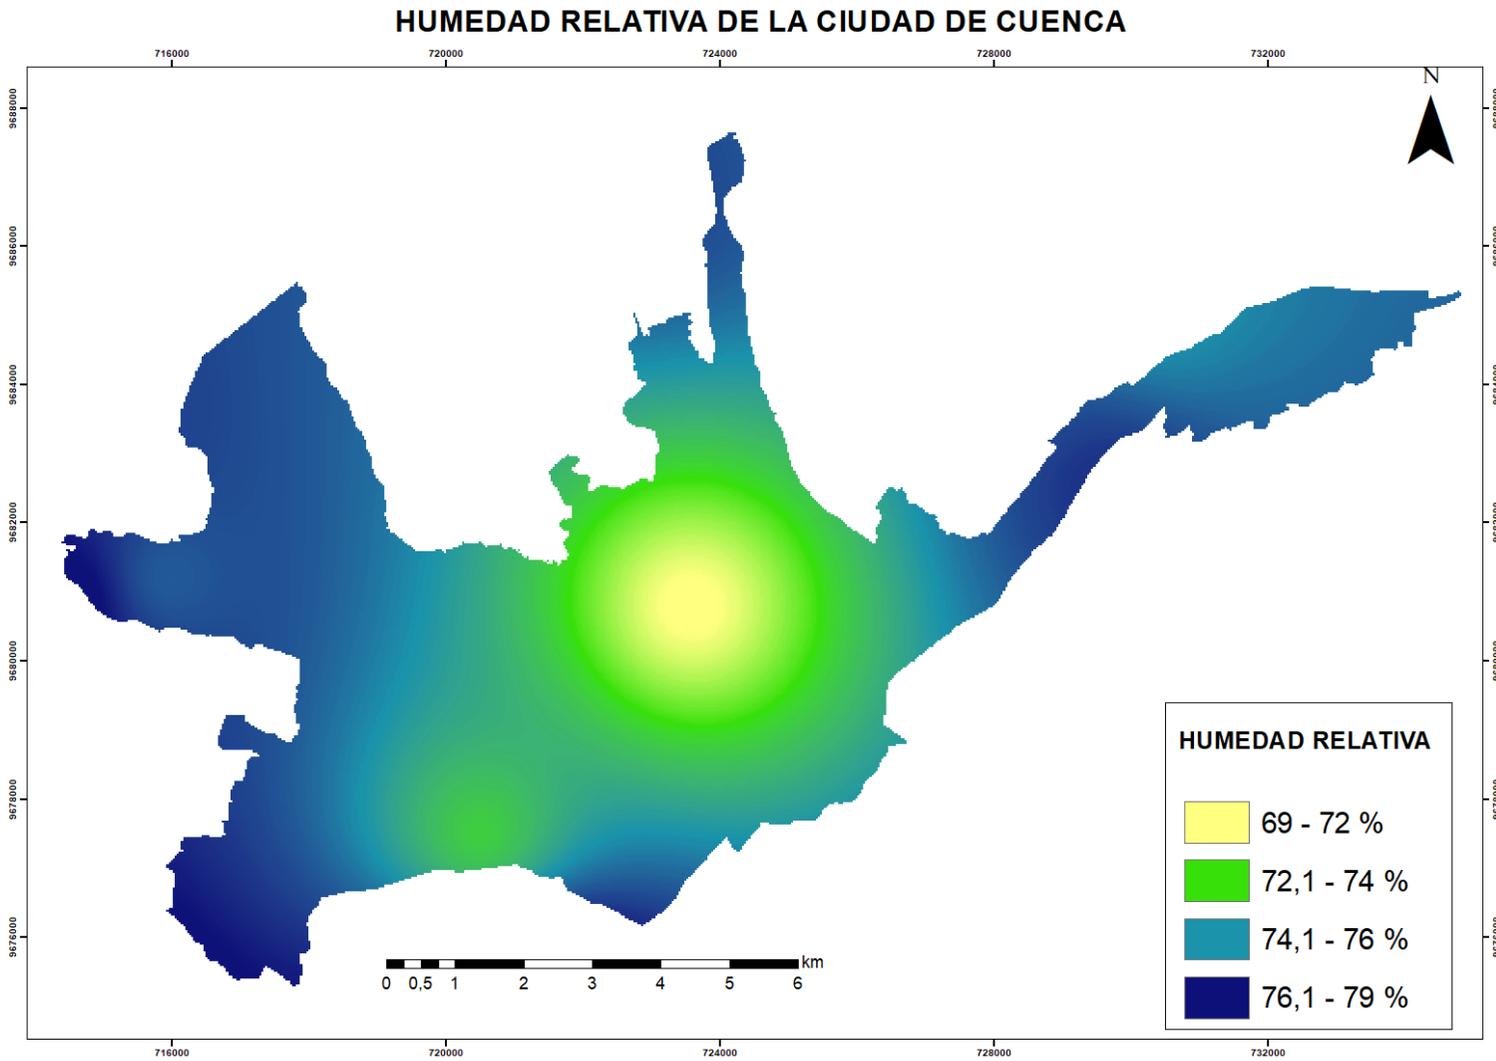
Por lo tanto, el efecto bruma es:

$$L_p = ML * ND_{min} + AL - \frac{0.01 * ESUN_{\lambda} * SEN_{(\theta SE)}}{\pi * d^2}$$

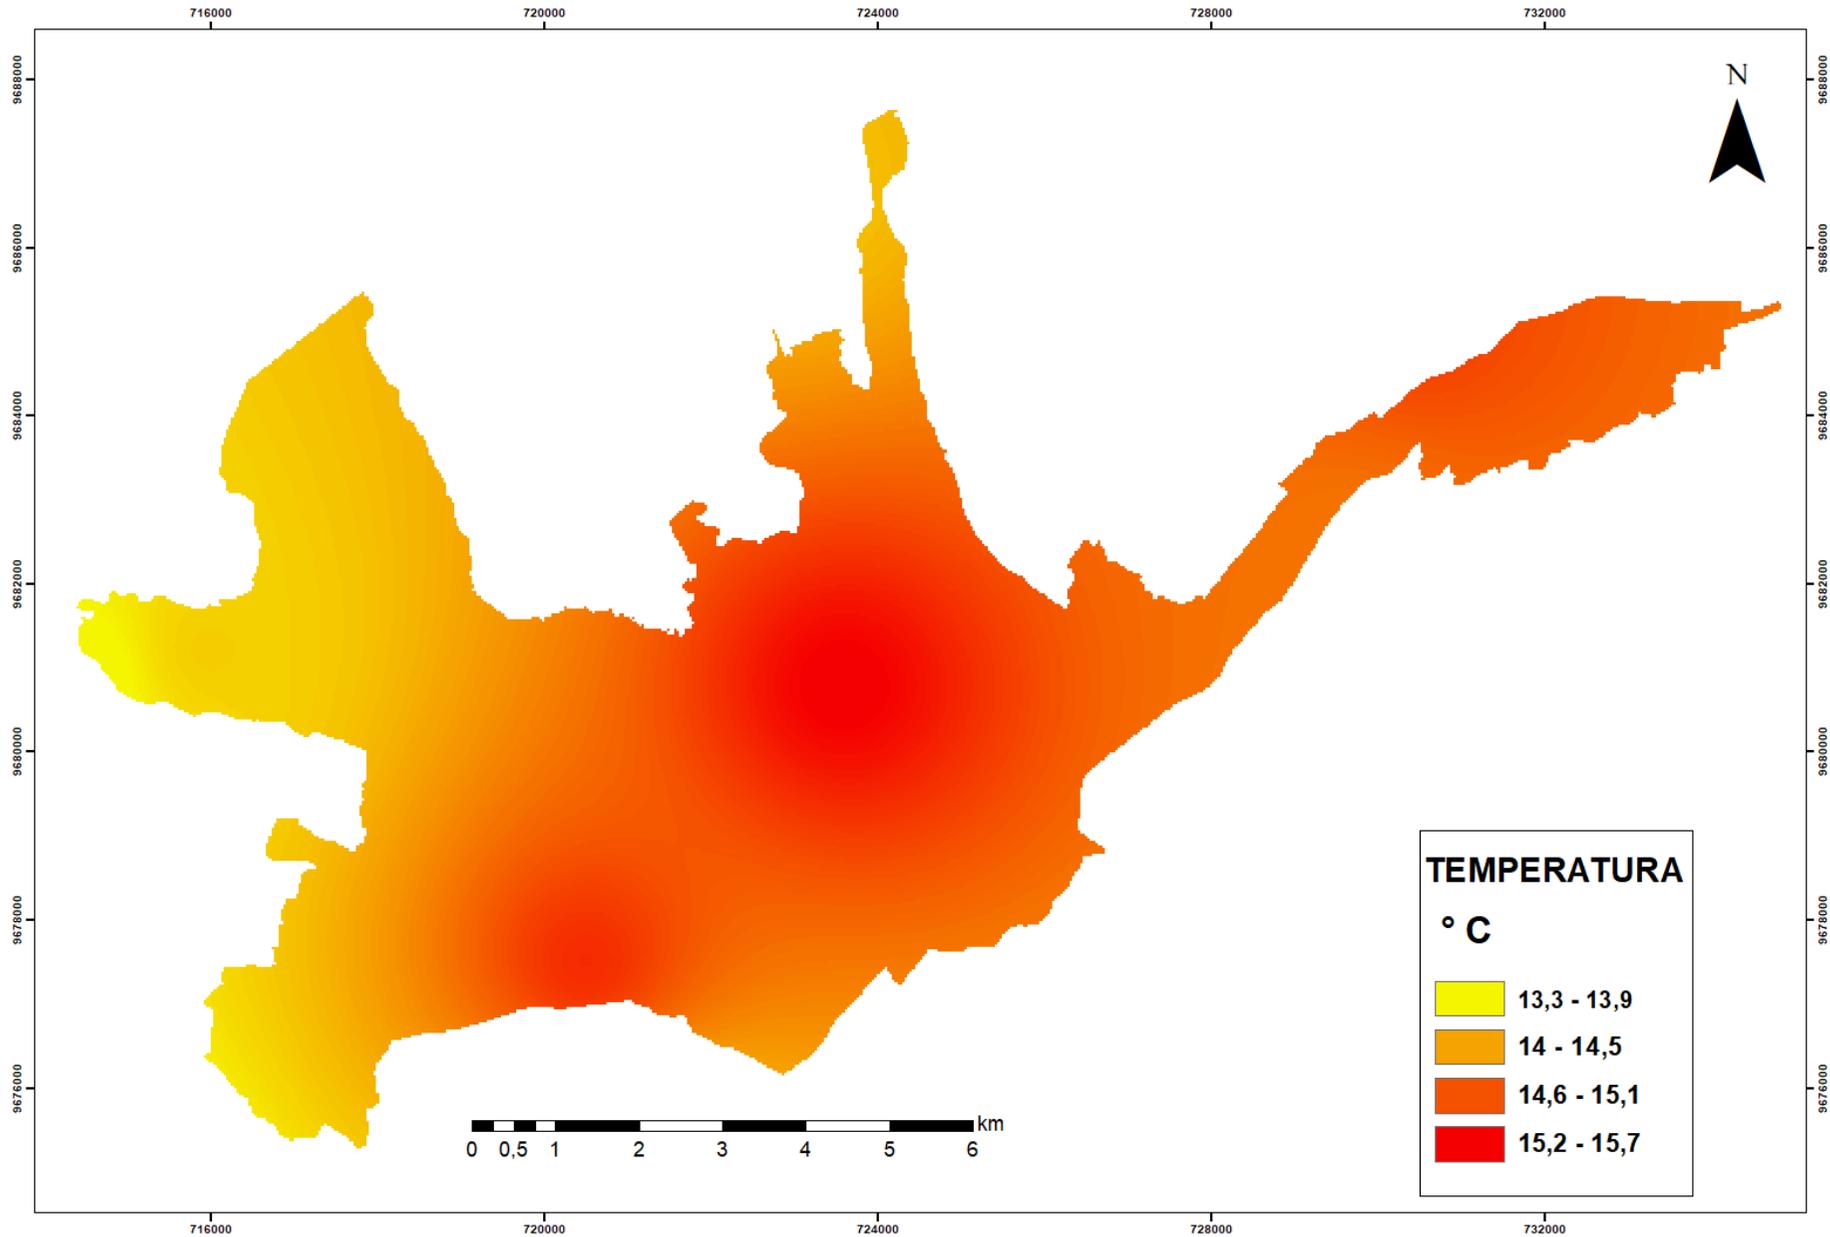
Anexo 2. Mapa de ubicación de las estaciones meteorológicas del cantón Cuenca.



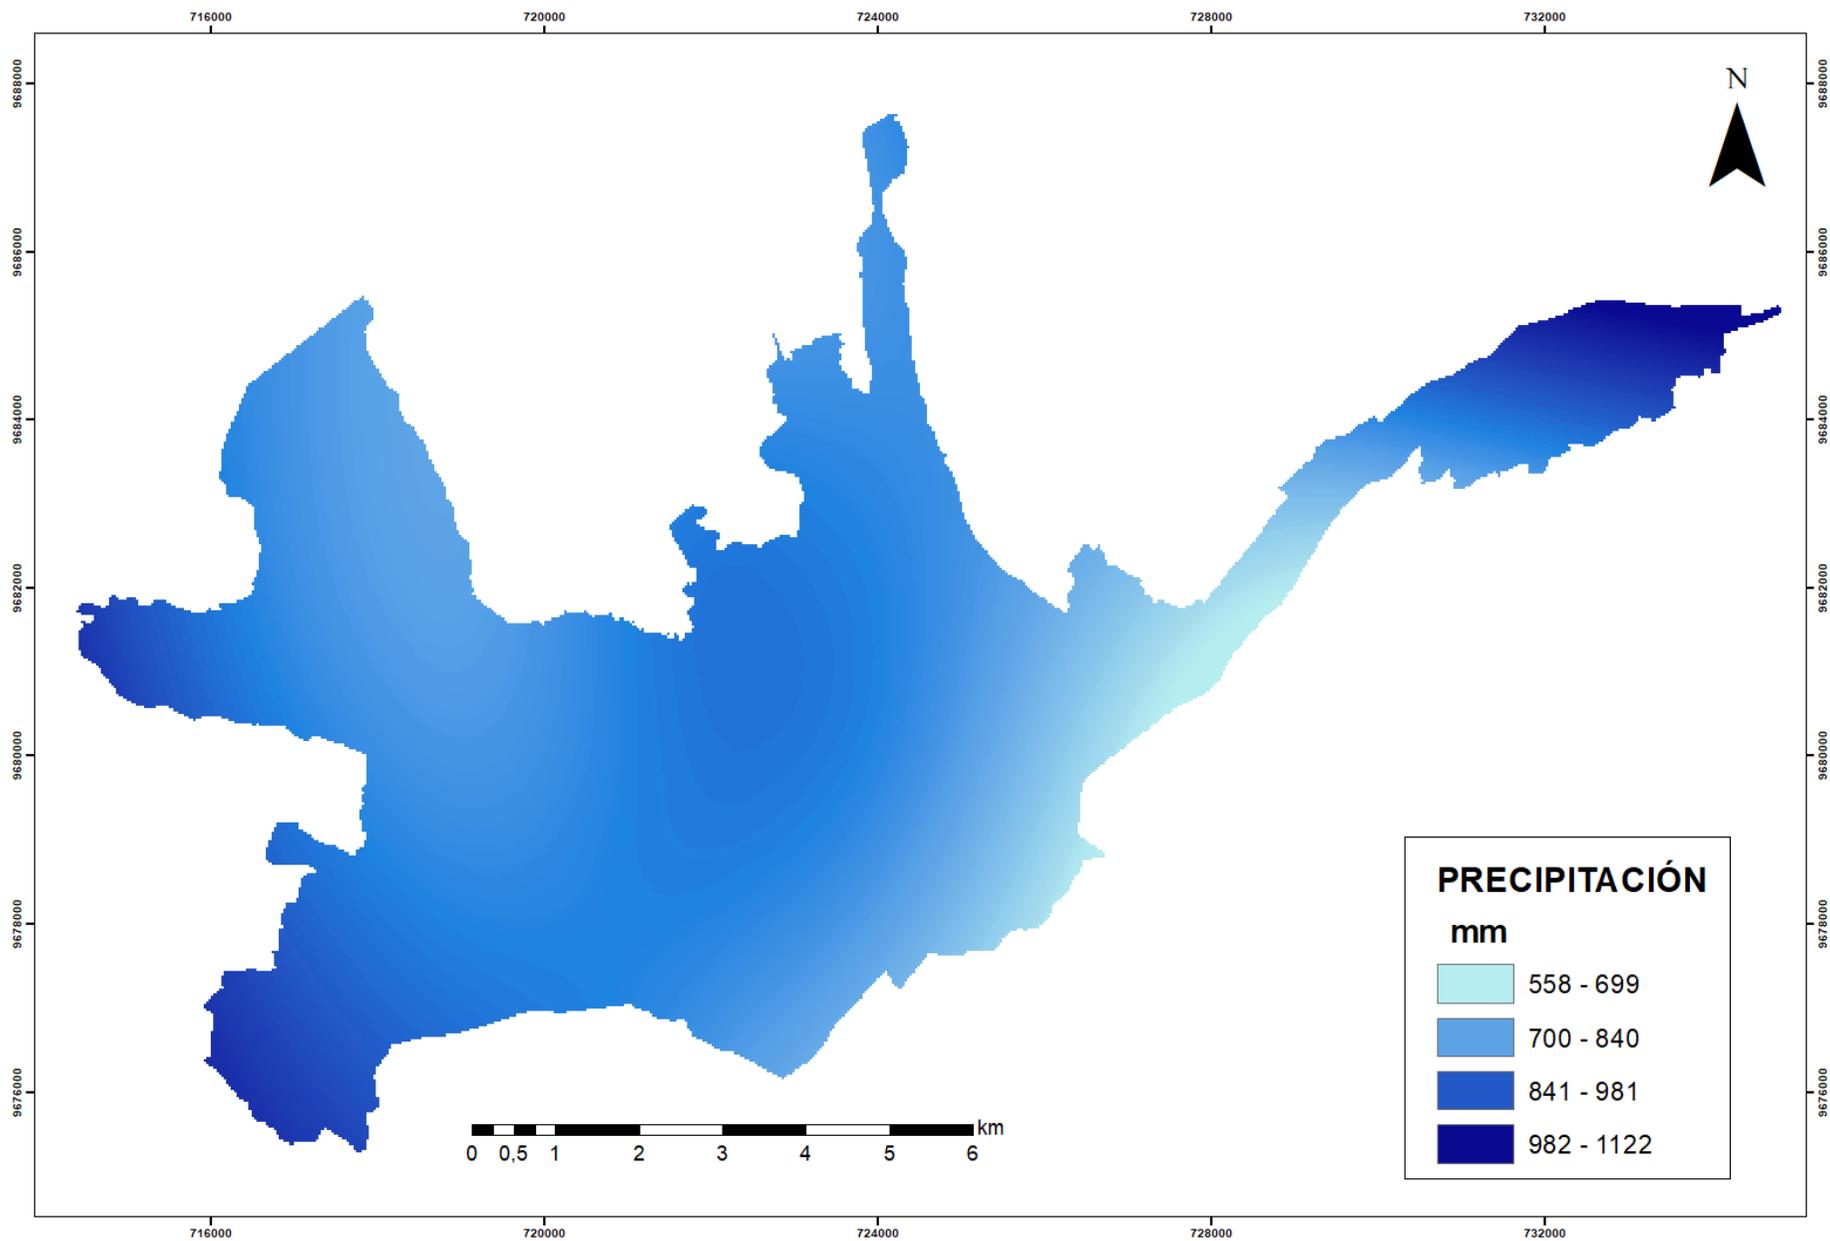
Anexo 3. Mapas de interpolación de humedad relativa, temperatura y precipitación mediante el modelo Kriging de la ciudad de Cuenca.



TEMPERATURA DE LA CIUDAD DE CUENCA



PRECIPITACIÓN DE LA CIUDAD DE CUENCA



Anexo 4. Matriz multivariante

Estación	NO2	BLUE TOA	GREEN TOA	RED TOA	NIR TOA	SWIR1 TOA	SWIR2 TOA	BLUE ATM	GREEN ATM	RED ATM	NIR ATM	SWIR1 ATM	SWIR2 ATM	EVI	MNDWI	MSAVI	MSI	NBR	NDBI	NDVI	SAVI	PP	HR	T
EVI	20,4167	0,1380	0,1404	0,1461	0,2189	0,2327	0,1964	0,1044	0,1331	0,1517	0,2458	0,2645	0,2333	0,1023	-0,3296	0,6122	0,5869	0,0299	0,0397	0,2357	0,1562	825,3280	73,2154	15,2187
MEA	24,0833	0,2049	0,2041	0,2169	0,2439	0,2889	0,2634	0,1275	0,1409	0,2286	0,2688	0,3182	0,2983	0,0415	-0,1716	0,5530	0,7183	-0,0673	0,0952	0,0783	0,0573	787,7880	75,2093	14,5291
ODO	20,6500	0,1110	0,1105	0,1188	0,1900	0,1937	0,1578	0,0703	0,0944	0,1224	0,2142	0,2178	0,1837	0,1001	-0,3593	0,5919	0,6337	0,0777	0,0079	0,2733	0,1645	788,5730	74,3968	14,7776
CHT	20,4833	0,1330	0,1330	0,1533	0,1762	0,2261	0,2042	0,1040	0,1261	0,1648	0,2035	0,2584	0,2413	0,0404	-0,2560	0,4865	0,6978	-0,0734	0,1073	0,0986	0,0644	818,0950	70,3344	15,4881
TET	27,1000	0,1894	0,1898	0,2017	0,2128	0,3427	0,3708	0,1228	0,1331	0,2198	0,2468	0,3880	0,4356	0,0327	-0,1793	0,4926	0,8677	-0,2595	0,2086	0,0488	0,0392	846,5260	70,2414	15,5039
MUN	21,8500	0,1165	0,1117	0,1281	0,1483	0,2000	0,1801	0,0927	0,1148	0,1310	0,1657	0,2235	0,2084	0,0385	-0,2977	0,4726	0,7821	-0,1143	0,1485	0,1175	0,0654	845,1890	73,1019	15,0018
EIE	23,4000	0,1418	0,1402	0,1491	0,1844	0,1990	0,1795	0,1021	0,1296	0,1557	0,2091	0,2235	0,2079	0,0640	-0,2249	0,5217	0,6663	0,0026	0,0337	0,1462	0,0923	850,6850	75,6269	14,5212
CRB	15,9500	0,1619	0,1591	0,1637	0,2623	0,2772	0,2095	0,1286	0,1584	0,1726	0,2977	0,3084	0,2416	0,1497	-0,3101	0,6789	0,6476	0,1043	0,0173	0,2661	0,1932	934,7990	77,3224	13,9312
BAL	18,4333	0,0920	0,0867	0,0828	0,1865	0,1582	0,1100	0,0507	0,0689	0,0803	0,2112	0,1798	0,1296	0,1531	-0,4557	0,6576	0,5223	0,2425	-0,0872	0,4410	0,2411	785,3820	76,1334	14,1571
EIA	18,7000	0,1765	0,1817	0,1955	0,2321	0,2741	0,2267	0,1139	0,2423	0,2089	0,2696	0,3036	0,2603	0,0744	-0,2267	0,5527	0,7215	0,0016	0,0707	0,1332	0,0917	673,3460	73,6328	14,9256
CCA	22,5167	0,1258	0,1259	0,1548	0,1918	0,2081	0,1762	0,0905	0,1227	0,1648	0,2193	0,2361	0,2070	0,0538	-0,3090	0,5253	0,6272	0,0353	0,0292	0,1430	0,0921	801,8860	70,8918	15,3859
ECC	18,2667	0,1500	0,1584	0,1609	0,2952	0,2634	0,1828	0,0677	0,1072	0,1631	0,3332	0,2924	0,2080	0,1842	-0,4089	0,7826	0,5734	0,2561	-0,0727	0,3944	0,2705	857,8800	71,2885	15,2899
EHS	14,8667	0,1237	0,1375	0,1457	0,2670	0,2631	0,1932	0,0880	0,1251	0,1539	0,3012	0,2910	0,2203	0,1396	-0,3759	0,7218	0,6290	0,1562	-0,0179	0,3231	0,2310	801,4910	74,0853	14,7481
BCB	44,4500	0,1314	0,1290	0,1414	0,1665	0,2019	0,1822	0,1318	0,1425	0,1453	0,1841	0,2254	0,2105	0,0414	-0,2493	0,4948	0,7176	-0,0724	0,1049	0,1155	0,0691	843,0480	73,3832	14,9631
LAR	33,3167	0,1172	0,1143	0,1347	0,1493	0,1888	0,1700	0,0831	0,0992	0,1411	0,1703	0,2115	0,1975	0,0325	-0,2565	0,4588	0,8061	-0,0767	0,1105	0,0940	0,0538	839,8930	73,7059	14,9264
VEG	43,6667	0,1139	0,1110	0,1306	0,1655	0,2082	0,1815	0,0784	0,0974	0,1343	0,1867	0,2331	0,2103	0,0581	-0,3338	0,5104	0,7540	-0,0596	0,1106	0,1632	0,0956	849,0650	72,5505	15,0805
MAN	15,1667	0,1155	0,1224	0,1629	0,2376	0,2773	0,2382	0,0863	0,1170	0,1740	0,2691	0,3090	0,2733	0,0814	-0,4178	0,6207	0,6963	-0,0070	0,0686	0,2155	0,1514	582,5330	76,0865	14,6811
CEB	18,4500	0,1163	0,1208	0,1253	0,2133	0,2122	0,1584	0,0848	0,1222	0,1299	0,2422	0,2386	0,1848	0,1210	-0,3672	0,6362	0,5999	0,1354	-0,0083	0,3036	0,1934	783,1830	74,9336	14,5203
MIS	14,6000	0,0975	0,1027	0,0997	0,2362	0,2054	0,1286	0,0535	0,0837	0,1012	0,2677	0,2315	0,1514	0,1752	-0,4699	0,7449	0,5549	0,2778	-0,0716	0,4507	0,2866	882,7650	76,7859	14,0312

