

**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO**

**CARRERA:
INGENIERÍA AMBIENTAL**

**Trabajo de titulación previo a la obtención del título de:
INGENIERAS AMBIENTALES**

**TEMA:
COMPARACIÓN EN LA ESTIMACIÓN DE MATERIAL PARTICULADO
PM10 USANDO IMÁGENES SATELITALES LANDSAT 7, LANDSAT 8 Y
MODIS EN QUITO**

**AUTORAS:
NELLY STEFANÍA TORRES SAQUINGA
VALERIA LIZBETH VIVANCO PÉREZ**

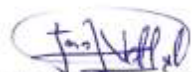
**TUTOR:
CÉSAR IVÁN ÁLVAREZ MENDOZA**

Quito, agosto del 2018

CESIÓN DE DERECHOS DE AUTOR

Nosotras, Nelly Stefanía Torres Saquina, con documento de identificación N.º 1726650953, y Valeria Lizbeth Vivanco Pérez con documento de identificación N.º 1718272659, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autoras del trabajo de titulación intitulado: **COMPARACIÓN EN LA ESTIMACIÓN DE MATERIAL PARTICULADO PM10 USANDO IMÁGENES SATELITALES LANDSAT 7, LANDSAT 8 Y MODIS EN QUITO**, mismo que ha sido desarrollado para optar por el título de INGENIERAS AMBIENTALES 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 nuestra condición de autoras nos reservamos los derechos morales de la obra antes citada. En concordancia, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.



.....
Nelly Stefanía Torres Saquina
1726650953



.....
Valeria Lizbeth Vivanco Pérez
1718272659

FECHA: Agosto, 2018

DECLARATORIA DE COAUTORÍA DEL TUTOR

Yo declaro que bajo mi dirección y asesoría fue desarrollado el Trabajo Experimental, **COMPARACIÓN EN LA ESTIMACIÓN DE MATERIAL PARTICULADO PM10 USANDO IMÁGENES SATELITALES LANDSAT 7, LANDSAT 8 Y MODIS EN QUITO**, realizado por Nelly Stefanía Torres Saquina y Valeria Lizbeth Vivanco Pérez, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana, para ser considerados como trabajo final de titulación.

Quito, agosto del 2018



CÉSAR IVÁN ÁLVAREZ MENDOZA

1720100922

DEDICATORIA

Dedico este logro principalmente a Dios por ser un refugio de paz y ser quien me ayudó en los tiempos de adversidad, brindándome sabiduría y fortaleza para afrontar momentos difíciles.

A mi madre Margarita, gracias por ser una mujer ejemplar que con rectitud me impulso a seguir adelante, siempre apoyándome incondicionalmente con palabras de aliento y cariño durante el desarrollo y culminación de este proyecto de investigación. A mi padre José, por ser la guía de mi vida y fomentarme buenos principios y valores. Gracias padres por confiar en mí y darme todo lo necesario para ser la persona profesional que ahora soy, sin ustedes me hubiese sido imposible cumplirlo, han sido un gran apoyo a lo largo de toda mi vida, siempre aconsejándome y haciéndome ver las cosas de la forma correcta cuando me equivoco, los quiero mucho, no los decepcionare y trataré cada día de ser la mejor.

A Majito, más que una amiga ha sido una verdadera hermana siempre junto a mí. Me siento bendecida al compartir mi amistad contigo. Eres una mujer muy valiosa, te prometo siempre estar a tu lado y no abandonarte como tú nunca lo has hecho.

A mis amigos: Allan, Fernando, Dayana, Alexis, Katherine, Marcelita, Jefferson, por brindarme una amistad incondicional, son realmente importantes en mi vida, más que amigos forman parte de mi familia, gracias por darme apoyo moral y compartir tantas experiencias, que siempre estarán guardadas en mi memoria, son excelentes personas que espero tener a mi lado toda mi vida, han hecho de mi vida estudiantil alegre mostrándome el verdadero significado de la amistad.

Nelly

Alguna vez alguien me dijo que una persona debe decir y escribir los sentimientos que emergen de su corazón al igual que el arte de dibujar en una parte converge. Estas líneas son para dedicar este pequeño logro primero a Dios ser supremo y creador quien coloca en tu camino a las personas adecuadas para contribuir tanto en tu formación profesional y personal.

A la memoria de mi abuelita María Emperatriz la persona más importante en mi vida, guía, apoyo, brazo incansable a mi lado desde que nací, la cual me enseñó a jamás desistir y que ningún sueño es inalcanzable simplemente es cuestión de perseverancia.

A mis padres Patricia y Vicente ejes fundamentales que con su amor, esfuerzo, cariño, paciencia y dedicación lograron que culmine este ciclo en mi vida.

A mis amigos por su apoyo incondicional a lo largo de la carrera y con quienes logramos superar los obstáculos presentes en especial a: Roberto, Erika, Daniel, Rosita, Andrés. No fue nada fácil pero los sueños se viven, ríen y gozan cuando dejas de lado todos tus miedos.

Valeria

AGRADECIMIENTOS

Deseamos expresar nuestro más sincero agradecimiento a Dios por llenarnos de paciencia, sabiduría y permitirnos compartir estos momentos con nuestros seres queridos.

A nuestras familias que con su apoyo constante no han permitido que desistamos.

A la Secretaría de Ambiente entidad que nos brindó la oportunidad de acceder a la información para la consecución del presente proyecto.

Así también a la Universidad Politécnica Salesiana a la Carrera de Ingeniería Ambiental por la formación académica brindada y a los docentes que la conforman en particular al PhD César Iván Álvarez Mendoza por su incansable dirección, enseñanza, paciencia a lo largo de este andar y que sin su imprescindible apoyo no se habría podido lograr el desarrollo de este trabajo.

A la Ing. Mat. Karen Calva Analista en la Dirección de Gestión de la Información y Procesos de la Escuela Politécnica Nacional por su colaboración en el desarrollo del modelo por Regresión Ponderada Geográficamente.

Nelly y Valeria

ÍNDICE

1. INTRODUCCIÓN.....	1
2. OBJETIVOS	4
2.1. Objetivo General	4
2.2. Objetivos específicos	4
3. MARCO TEÓRICO.....	5
3.1. Teledetección Espacial.....	5
3.1.1. Espectro electromagnético.....	5
3.1.2. Elementos de la percepción remota.....	6
3.2. Principios y bases físicas de la captura de información a distancia.....	7
3.2.1. Pixel.....	8
3.2.2. Creación de pirámides	8
3.2.3. Bit	9
3.3. Resolución que ofrecen los distintos sensores remotos	9
3.3.1. Resolución	9
3.3.1.1. Resolución radiométrica	9
3.3.1.2. Resolución espectral	10
3.3.1.3. Resolución espacial.....	11
3.3.1.4. Resolución temporal	12
3.4. Plataformas para descargar imágenes satelitales.....	13
3.5. Sensores remotos utilizados en Teledetección	13

3.5.1.	Landsat 7	13
3.5.2.	Landsat 8	14
3.5.3.	MODIS	14
3.6.	Correcciones de las imágenes	16
3.6.1.	Corrección topográfica	16
3.6.2.	Corrección radiométrica	16
3.6.3.	Corrección geométrica.....	18
3.6.4.	Corrección atmosférica.....	19
3.6.4.1.	Corrección atmosférica para datos térmicos	20
3.7.	Índices espectrales.....	22
3.7.1.	Índices de vegetación	22
3.7.2.	Temperatura de Brillo	23
3.7.3.	Índice de diferencia normalizada de suelos.....	24
3.7.4.	Índice de agua de diferencia normalizada	25
3.7.5.	Índice de vegetación de diferencia normalizada	25
3.8.	Mínimos Cuadrados Parciales.....	26
3.9.	Regresión GWR “Geographically weighted regression”	27
3.9.1.	Forma de trabajo de la regresión ponderada geográficamente	29
3.9.2.	Ancho de banda variable “h” o adaptive distance kernel	31
3.10.	Regresión lineal generalizada	32

4. MATERIALES Y MÉTODOS	34
4.1. Materiales y Métodos	34
4.1.1. Landsat 7	34
4.1.2. Landsat 8	35
4.1.3. MODIS	35
4.2. Área de Estudio	38
4.3. Hardware empleado	38
4.4. Software empleado.....	38
4.5. Recopilación de información	39
4.6. Preprocesamiento de imágenes satelitales	40
4.6.1. Corrección radiométrica	40
4.6.2. Corrección atmosférica.....	41
4.7. Cálculo de los índices ambientales	41
4.7.1. Índice diferencial de vegetación normalizado (NDVI)	41
4.7.2. Índice diferencial de agua normalizado (NDWI)	42
4.7.3. Índice de vegetación ajustado al suelo (SAVI)	42
4.7.4. Índice de diferencia normalizada de Suelos (NSI)	42
4.7.5. Temperatura.....	43
4.7.6. Temperatura de brillo	46
4.7.7. Temperatura de superficie	47

4.8.	Creación de matriz con los indicadores medioambientales	48
4.9.	Modelos de predicción de PM ₁₀	48
5.	RESULTADOS Y DISCUSIÓN.....	50
5.1.	Sensor “Landsat 7”.....	50
5.1.1.	Análisis de información de recopilada de PM ₁₀	50
5.1.2.	Descripción de la data	52
5.1.3.	Análisis de los modelos generados.....	59
5.1.3.1.	Modelos 1 ,2 ,3: Regresión lineal generalizada sin transformación logarítmica sensor “Landsat 7”	59
5.1.3.2.	Modelo 4 , 5 y 6 : Regresión ponderada geográficamente para el sensor “LANDSAT 7 “	65
5.1.3.2.1.	Validación cruzada del ancho de banda para la Regresión Ponderada Geográficamente “Landsat 7”	66
5.1.3.2.1.1.	Descripción	66
5.1.3.2.1.2.	Fórmula.....	67
5.1.3.2.1.3.	Argumentos.....	67
5.1.3.2.2.	Modelo de Regresión Ponderada Geográficamente	68
5.1.3.2.2.1.	Descripción	68
5.1.3.2.2.2.	Fórmula.....	68
5.1.3.2.2.3.	Argumentos.....	68

5.2.	Resumen estadístico de los modelos planteados basados en el método de Regresión Geográficamente Ponderada	70
5.3.	Sensor “Landsat 8”	81
5.3.1.	Análisis de información recopilada de PM ₁₀	81
5.3.2.	Descripción de la data	82
5.3.3.	Análisis de los modelos generados para el sensor "Landsat 8"	86
5.3.3.1.	Modelo 7, 8, 9: Regresión lineal generalizada sin transformación logarítmica sensor “Landsat 8”.	87
5.3.3.2.	Modelo 10, 11: Regresión Ponderada Geográficamente para el sensor Landsat 8.....	91
5.4.	Resumen estadístico de los modelos para el sensor “Landsat 8”	92
5.5.	Sensor “MODIS”	101
5.5.1.	Análisis de información recopilada de PM ₁₀	101
5.5.2.	Descripción de la data	102
5.5.3.	Análisis de los modelos generados.....	107
5.5.3.1.	Modelo 12, 13, 14: Regresión lineal generalizada sin transformación logarítmica para el sensor “MODIS”	107
5.5.3.2.	Modelo 15 y 16: Regresión Ponderada Geográficamente	113
5.6.	Resumen estadístico de los modelos ponderados geográficamente para el sensor “MODIS”	113

5.7.	Comparación de todos los modelos generados para estimar el PM ₁₀ en la REMMAQ por sensor	123
5.8.	DISCUSIÓN	125
6.	CONCLUSIONES Y RECOMENDACIONES	129
6.1.	Conclusiones	129
6.2.	Recomendaciones.....	129
7.	BIBLIOGRAFÍA	132
8.	ANEXOS	145

ÍNDICE DE TABLAS

Tabla 1. Plataformas de descarga de imágenes satelitales	13
Tabla 2. Resumen de imágenes procesadas para el presente estudio.....	49
Tabla 3. Valor de la mediana para cada estación de la REMMAQ.	51
Tabla 4. Descripción de los datos de investigación para el sensor “Landsat 7”	52
Tabla 5. Correlación existente entre variables dependientes y variables independientes para el sensor “Landsat 7”.....	56
Tabla 6. Análisis estadístico de modelos resultantes del sensor satelital “Landsat 7”....	60
Tabla 7. Análisis de varianza de 3 modelos generalizados lineales y modelo lineal multivariable para el sensor “Landsat 7”	61
Tabla 8. Comparación de los modelos generados para el sensor “Landsat 7”.....	70
Tabla 9. Resumen de la regresión ponderada geográficamente del Modelo 6 para el sensor “Landsat 7”.	74
Tabla 10. Análisis de varianza del Modelo 6 para el sensor “Landsat 7”	77
Tabla 11. Descripción de los datos de investigación para el sensor “Landsat 8”	82
Tabla 12. Correlación existente entre variables dependientes y variables independientes para el sensor “Landsat 8”.....	85
Tabla 13. Análisis estadístico de modelos resultantes del sensor satelital “Landsat 8”..	87
Tabla 14. Análisis de varianza de los modelos generalizados lineales y el modelo lineal multivariante para el sensor “Landsat 8”.	88
Tabla 15. Comparación de los modelos generados para el sensor “Landsat 8”.....	92
Tabla 16. Resumen de la regresión ponderada geográficamente con datos atípicos para el sensor “Landsat 8”.	94
Tabla 17. Análisis de varianza de Modelo 11 para el sensor “Landsat 8”.....	97

Tabla 18. Descripción de los datos para el sensor “MODIS”	102
Tabla 19. Correlación entre variables dependientes y variables independientes para el sensor “MODIS”.	105
Tabla 20. Análisis estadístico de los modelos resultantes para el sensor “MODIS”	108
Tabla 21. Análisis de varianza de los modelos para el sensor “MODIS”	108
Tabla 22. Comparación de los modelos generados para el sensor “MODIS”	114
Tabla 23. Resumen de la regresión ponderada geográficamente para el sensor “MODIS”.	116
Tabla 24. Análisis de varianza del Modelo 16 para el sensor “MODIS”	119
Tabla 25. Resumen estadístico de los modelos generados	123
Tabla 26. Coordenadas de las estaciones automáticas y pasivas del Distrito Metropolitano de Quito.	145
Tabla 27. Bandas del espectro electromagnético (microondas)	149
Tabla 28. Resolución espacial de sensores	149
Tabla 29. Bandas espectrales “Landsat 7”	150
Tabla 30. Características de los principales sensores utilizados en teledetección	150
Tabla 31. Bandas espectrales “Landsat 8”	151
Tabla 32. Bandas espectrales “MODIS”	152

ÍNDICE DE FIGURAS

Figura 1. Elementos de la percepción remota	6
Figura 2. Sensibilidad de imágenes a diferentes bytes.....	10
Figura 3. Sensores y satélites de teledetección consecuencias de la resolución espacial	11
Figura 4. Resolución temporal	12
Figura 5. Gráficas de relación entre dos variables	27
Figura 6. Esquema de ponderación típica	30
Figura 7. Esquema de la función de kernel ancho de banda fijo para la búsqueda de vecindad.	31
Figura 8. Esquema de la función kernel de tipo variable y búsqueda de vecindad mediante la aplicación de esta técnica.	32
Figura 9. Metodología aplicada	37
Figura 10. Metodología aplicada para obtención de temperatura.....	44
Figura 11. Matriz con parámetros medioambientales	48
Figura 12. Diagrama de cajas del PM ₁₀ por estación en el remmaq.	51
Figura 13. Gráficas de dispersión de la variable PM ₁₀ vs. NDVI, NDWI, LST, NSI, SAVI (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “Landsat 7”.	54
Figura 14. Gráficas de dispersión de la variable PM ₁₀ vs. BAND_NIR, BAND_SWIR (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “Landsat 7”	55
Figura 15. Gráficas de dispersión, ajuste lineal y ancho de banda al 95% entre log (PM ₁₀) vs. Band blue, red, green, swir, nir sensor “Landsat 7”.	58

Figura 16. Gráficas de análisis de residuos del modelo lineal generalizado seleccionado para el sensor “Landsat 7”	63
Figura 17. Clasificación de PM ₁₀ estimado para el año 2013.....	64
Figura 18. Clasificación de PM ₁₀ estimado para el año 2015.....	64
Figura 19. Clasificación de PM ₁₀ estimado para el año 2017.....	65
Figura 20. Diagrama de cajas para PM ₁₀ por estación.....	66
Figura 21. Gráficas de residuales vs. Patrones ajustados y Normal Q-Q en “Landsat 7”.	71
Figura 22. Dispersión del material particulado observado y ajustado mediante una regresión lineal multivariada.....	71
Figura 23. Dispersión de PM ₁₀ observado y estimado mediante GWR.....	77
Figura 24. Dispersión de los residuos del Modelo 6.....	78
Figura 25. Ajuste Q-Q Normal e Histograma de ajuste normal de los residuos con un intervalo de confianza al 99% sensor “Landsat 7”	78
Figura 26. Clasificación de PM ₁₀ estimado para el año 2013.....	79
Figura 27. Clasificación de PM ₁₀ estimado para el año 2015.....	80
Figura 28. Clasificación de PM ₁₀ estimado para el año 2017.....	80
Figura 29. Diagrama de cajas del PM ₁₀ por estación en la REMMAQ.	81
Figura 30. Gráficas de dispersión de la variable PM ₁₀ vs. NDVI, NDWI, LST, NSI, SAVI (ajuste de regresión polinomial local) con un intervalo de confianza del 95% para el sensor “Landsat 8”	83
Figura 31. Gráficas de dispersión de la variable PM ₁₀ vs. BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR (ajuste de regresión	

polinomial local) con un intervalo de confianza del 95% para el sensor “Landsat 8”	84
Figura 32. Gráficas de dispersión, ajuste lineal y ancho de banda al 95% entre log (PM ₁₀) vs. (BAND BLUE, RED, GREEN, NIR* SWIR) sensor “Landsat 8”.....	86
Figura 33. Gráficas de análisis de los residuos del Modelo 8 para el sensor "Landsat 8".	89
Figura 34. Clasificación de PM ₁₀ estimado para el año 2013.....	90
Figura 35. Clasificación de PM ₁₀ estimado para el año 2015.	90
Figura 36. Clasificación de PM ₁₀ estimado para el año 2017.....	91
Figura 37. Gráficas de residuos vs. Ajustados y Normal Q-Q para “Landsat 8”.....	93
Figura 38. Dispersión del material particulado (PM ₁₀) observado y ajustado mediante el Modelo 11.	97
Figura 39. Dispersión de residuos del Modelo 11 para el sensor “Landsat 8”.	98
Figura 40. Ajuste Q-Q Normal e histograma de ajuste normal de los residuos con un intervalo de confianza al 99% sensor “Landsat 8”.....	98
Figura 41. Clasificación de PM ₁₀ estimado para el año 2013.	99
Figura 42. Clasificación de PM ₁₀ estimado para el año 2015.....	100
Figura 43. Clasificación de PM ₁₀ estimado para el año 2017.....	100
Figura 44. Diagrama de cajas del PM ₁₀ por estación en la REMMAQ.	101
Figura 45. Gráficas de dispersión de la variable PM ₁₀ vs. NDVI, NDWI, LST, NSI, SAVI (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “MODIS”.	103

Figura 46. Gráficas de dispersión de la variable PM_{10} vs. B1, B2, B3, B4, B5 (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “MODIS”.	104
Figura 47. Gráficas de dispersión, ajuste lineal y ancho de banda al 95% entre log (PM_{10}) vs. (BAND B1, B2, B3, B4, B5) y log (PM_{10}) vs. (NDVI*SAVI) sensor “MODIS”.	106
Figura 48. Gráficas de análisis de residuos del Modelo 14 para el sensor “MODIS”.	110
Figura 49. Clasificación de PM_{10} estimado para el año 2013.	111
Figura 50. Clasificación de PM_{10} estimado para el año 2015.	112
Figura 51. Clasificación de PM_{10} estimado para el año 2017.	112
Figura 52. Gráficas de residuos vs. Ajustados y Normal Q-Q del Modelo 15 para el sensor “MODIS”.	114
Figura 53. Gráfico de dispersión del material particulado (PM_{10}) observado y ajustado mediante el Modelo 16.	119
Figura 54. Gráfico de dispersión de residuos del Modelo 16 para el sensor “MODIS”.	120
Figura 55. Ajuste Q-Q Normal e histograma de ajuste normal de los residuos con un intervalo de confianza al 99% sensor “MODIS”.	120
Figura 56. Clasificación de PM_{10} estimado mediante el Modelo 16 para el año 2013.	121
Figura 57. Clasificación de PM_{10} estimado mediante el Modelo 16 para el año 2015.	122
Figura 58. Clasificación de PM_{10} estimado mediante el Modelo 16 para el año 2017.	122
Figura 60. Aplicación de herramienta radiometric calibration con archivo geotiff with mtl	146
Figura 61. Calibración de la imagen satelital	146

Figura 62. Imagen satelital luego de corrección radiométrica	147
Figura 63. Valores obtenidos del histograma.....	148
Figura 64. Parámetros de dark subtraction.....	148

ÍNDICE DE ANEXOS

Anexo A. Coordenadas de las estaciones automáticas y pasivas del Distrito Metropolitano de Quito.....	145
Anexo B. Corrección radiométrica de imagen satelital para el sensor “Landsat 7”	146
Anexo C. Histograma luego de aplicar dark subtraction.....	148
Anexo D. Bandas del espectro electromagnético y resolución espacial de sensores.....	149
Anexo E. Características principales de los sensores más utilizados en teledetección y bandas espectrales “Landsat 7”	150
Anexo F. Bandas espectrales que conforman al sensor “MODIS” y “Landsat 8”	151

RESUMEN

COMPARACIÓN EN LA ESTIMACIÓN DE MATERIAL PARTICULADO PM₁₀ USANDO IMÁGENES SATELITALES LANDSAT 7, LANDSAT 8 Y MODIS EN QUITO

El deterioro de la calidad del aire en los últimos años es uno de los principales problemas a los que se enfrentan la mayoría de las ciudades ya que provoca enfermedades pulmonares, cáncer de pulmón a la población expuesta y Quito no es la excepción. Mediante la aplicación de herramientas como la teledetección se pudo estimar uno de los principales contaminantes emitidos al aire denominado material particulado (PM₁₀), monitoreado por la Red Metropolitana de Monitoreo Atmosférico de Quito (REMMAQ) mediante las estaciones automáticas y pasivas ubicadas a lo largo de la ciudad. Se empleó imágenes satelitales provistas por sensores remotos (Landsat 7, Landsat 8 y MODIS) durante el periodo 2003-2017, además de la generación de una serie de indicadores ambientales a partir de las bandas multiespectrales usando el software ArcGis 10.5. Adicionalmente se crearon modelos de predicción a partir de éstas, tanto por regresión lineal generalizada (GLM) y regresión ponderada geográficamente (GWR) a partir de promedios cuatrimestrales. Las estaciones de Carapungo y Guamaní exceden el límite máximo de la OMS 50 µg/m³ debido al predominio del transporte público, industria de la construcción y actividades asociadas a fuentes industriales. Para predecir el PM₁₀ se empleó una matriz multivariable para cada sensor y se determinó que las imágenes provistas por el sensor “Landsat 8” y ajustado mediante un modelo GWR con n= 218 observaciones evidencia el mejor criterio de Akaike AIC= -12.73, R² Aj = 0.8339, y sus residuos cumplen los criterios de validación, por tanto brinda el mejor ajuste del PM₁₀.

Palabras claves: PM₁₀, calidad del aire, REMMAQ, indicadores, GWR

ABSTRACT

COMPARISON IN THE ESTIMATION OF PARTICULATE MATERIAL PM₁₀ USING SATELLITE IMAGES LANDSAT 7, LANDSAT 8 AND MODIS IN QUITO

The deterioration of air quality in recent years is one of the main problems that most cities already cause lung diseases, lung cancer to the exposed population and Quito is no exception. Through the application of tools such as remote sensing it was possible to estimate one of the main pollutants emitted into the air called particulate material (PM₁₀), monitored by the Quito Metropolitan Atmospheric Monitoring Network (REMMAQ) through the automatic and passive stations located along the city.

We used satellite images provided by remote sensors (Landsat 7, Landsat 8 and MODIS) during the period 2003-2017, as well as generating a series of environmental indicators from the multispectral bands using the ArcGis 10.5 software. In addition, predictive models were created from miles, both by generalized linear regression (GLM) and geographically weighted regression (GWR) from quarterly averages. The stations of Carapungo and Guamaní exceeded the WHO maximum limit of 50 µg/m³ due to the predominance of public transport, the construction industry and activities associated with industrial sources. To predict the PM₁₀ a multivariate matrix was used for each sensor and it was determined that the images provided by the “Landsat 8” sensor and the format using a GWR model with n = 218 observations tests the best criterion of Akaike AIC = -12.73, R² Aj = 0.8339, and its residues meet the validation criteria, thus providing the best fit of PM₁₀.

Keywords: PM₁₀, air quality, REMMAQ, indicators, GWR

1. INTRODUCCIÓN

El problema del aumento en el nivel de contaminación del aire se ha evidenciado en los últimos años especialmente en zonas urbanas; para cumplir con lo establecido en la Constitución del Ecuador y garantizar un ambiente sano, surgió entonces el Plan Nacional de Calidad del Aire fundamentado en Políticas Ambientales Nacionales y que a su vez consta de tres programas con sus respectivos proyectos, uno de ellos enmarcado en la generación de modelos predictivos de la calidad del aire cuyo objetivo es la simulación tanto de contaminantes primarios y secundarios (Ministerio del Ambiente, 2010).

Uno de los contaminantes criterio es el PM_{10} (material particulado), la importancia de estimar éste es debido a que perjudica la salud humana afectando la población especialmente niños y ancianos, atribuyéndolo diversas enfermedades respiratorias entre ellas: tuberculosis, silicotuberculosis, fibrosis, problemas cardiovasculares y cáncer del pulmón (Dirección Metropolitana de Medio Ambiente, 2011; Pope *et al.*, 1995)

El PM_{10} , se genera por las diferentes actividades antropogénicas y naturales tales como: transporte, calefacción, erupciones volcánicas, incendios forestales, producción de energía eléctrica, incineración de desechos, combustión de las industrias y emisiones debidas a los procesos de las mismas (Artiñano, Salvador, Alonso, Querol, & Alastuey, 2003).

A través de los años se han desarrollado nuevas técnicas que permitieron la detección de la contaminación del aire, mediante la obtención de información multiespectral a partir de imágenes satelitales provenientes de sensores remotos (Centro Internacional de Agricultura Tropical (CIAT), 2007).

En el caso de Ecuador resulta un campo muy poco explorado, la investigación de este contaminante fue realizada por (Alvarez Mendoza, 2014a) en Quito y se consideró

los años 2005, 2008, 2011 a partir de datos originados de imágenes satelitales y con indicadores ambientales tales como: NDVI- cobertura vegetal, LWCI- contenido de agua en hojas, TB- temperatura de brillo, SAVI- reflectividad de suelo, NSI- áreas de suelo desnudo, se generó modelos individuales mediante regresiones lineales múltiples considerando la Red Metropolitana de Monitoreo Atmosférico de Quito (REMMAQ) además de implicar tres bandas visibles de las imágenes satelitales concluyendo que los valores de radiancia de éstas se ven afectadas de manera directa por PM_{10} .

Así mismo se desarrolló un estudio en la estimación de material particulado menor a 10 micras a través de sensores remotos en el área urbana de la ciudad de Cuenca (Abad, 2016) en la que se desarrolló un modelo de regresión lineal múltiple estableciendo correlaciones que se obtuvieron a través de los datos obtenidos de mediciones terrestres de PM_{10} en la red de monitoreo de esta ciudad con los valores de imágenes satelitales Landsat 8.

En gran parte de los estudios publicados a nivel mundial emplean diferentes metodologías como, por ejemplo: (Guo et al., 2014) estimó la concentración de $PM_{2.5}$ en Beijing, China por medio de mediciones de profundidad óptica de aerosol de columna generados a partir de imágenes MODIS, obteniendo una correlación de 0.95 y concluyendo que la teleobservación por satélite presenta un gran potencial en la estimación de este contaminante y que además se constituyó en una herramienta clave para vigilar el ambiente atmosférico.

(Haamed & Hasan, 2014) por su parte producen un modelo empírico en la que la concentración de PM_{10} se hizo mediante bandas visibles de la imagen emitida por el satélite Landsat 8, en la ciudad de Kirkuk-Iraq en este estudio se crearon trece modelos y

de estos de eligió aquel que tuvo mayor coeficiente de determinación (0.834) y el de menor error cuadrático medio (11.836), este estudio concluyó que las bandas visibles de LANDSAT 8 OLI calculan con un nivel aceptable de precisión la concentración de material particulado.

2. OBJETIVOS

2.1. Objetivo General

Determinar la influencia del PM_{10} en la ciudad de Quito.

2.2. Objetivos específicos

- Generar estadística de datos de PM_{10} históricos entre los años 2003 al 2017.
- Procesar las imágenes satelitales.
- Generar modelos de comparación mediante PLS (Partial Least Square).

3. MARCO TEÓRICO

3.1. Teledetección Espacial

La teledetección es una técnica actual mediante la cual se obtiene imágenes satelitales, a pesar de que exista una gran distancia entre el objeto y el sensor remoto con la ayuda de la luz del sol a través de un intercambio de energía (Vargas-Cuentas, Román-González, Mantari, & Muñoz, 2018). Para que exista la teledetección es necesario contar con un sistema físico, una fuente luminosa y el sensor remoto, esta puede ser utilizada para numerosas aplicaciones entre las cuales se encuentran: monitoreo ambiental, recursos hidrológicos y planificación territorial (Vargas-Cuentas *et al.*, 2018).

El empleo de imágenes satélites se constituye en una innovadora herramienta tecnológica ya que se puede determinar el grado de afectación en el ambiente en torno a la variable de estudio gracias a la combinación de colores entre las bandas espectrales (Vargas-Cuentas *et al.*, 2018).

El intercambio de energía se da principalmente por la energía que contiene los objetos como cubiertas terrestres la cual es transmitida al sistema de recepción después de la interacción entre el objeto y el sensor producido por el flujo energético ocasionado por la propagación de ondas (Chuvienco, 2000).

3.1.1. Espectro electromagnético

Todos los cuerpos tienen su propia energía y esta a su vez se ve reflejada en una sucesión de valores λ_i de manera continua transmitiendo una gran cantidad de flujo energético para un determinado λ_i , diferenciando de esta manera ,unas fuentes de otras (Arozarena, Otero, & Ezquerro, 2016).

La sucesión continua de estos valores λ_i de constitución similar es lo que toma el nombre de espectro electromagnético ordenándose de acuerdo a las longitudes de onda λ_i

(bandas) cuyas unidades son en micrómetros las “ondas cortas” y en cm o m las “ondas largas”(Arozarena *et al.*, 2016). En la Tabla 27 del Anexo D se presenta las bandas del espectro electromagnético con su respectiva longitud de onda y abreviatura.

3.1.2. Elementos de la percepción remota

Con el avance de la ciencia y la tecnología se han incorporado una serie de métodos y dispositivos de captura de datos a distancia, permitiendo de este modo que la percepción remota tenga un amplio campo de acción a una diversidad de fenómenos, limitándose no solo al mundo macroscópico sino también al microscópico (Lira, 2011).




Figura 1. Elementos de la percepción remota

Fuente: Geoservice. (2015) componentes de un sistema de percepción remota. [Online]. Disponible en: http://geoservice.igac.gov.co/contenidos_telecentro/fundamentos_pr-semana1-unidad1/index.php?id=3

Los elementos de percepción remota están compuestos por (Lira, 2011):

- Fuente de iluminación

Existe una percepción remota la cual utiliza una fuente de iluminación externa misma que no se somete a un control a esto se lo denomina sistema pasivo, usa el sol o bien una estrella lejana (Lira, 2011). Otra forma de percepción remota son los sistemas activos estos ocupan su propia fuente de iluminación razón por la cual se tiene control sobre ella permitiendo de esa manera extender el campo de la percepción remota a una serie de fenómenos donde la fuente de iluminación ya no emite luz visible para iluminar la escena (Lira, 2011).

- Elemento Físico

El paisaje se caracteriza por ser uno de los instrumentos que más retos ponen al investigador en la percepción remota ya que es una parte muy compleja donde interviene muchos factores como algunos de ellos ajenos al investigador, además de que este no puede controlar situaciones adversas a este elemento (Lira, 2011).

3.2.Principios y bases físicas de la captura de información a distancia

Los elementos fundamentales empleados para la captura de información a distancia son: radiación electromagnética, leyes físicas ya que actúan en los diferentes procesos tales como: dispersión, absorción, reflexión (Arozarena *et al.*, 2016). Su objetivo radica en capturar un objeto y las propiedades de este, el sensor y el tipo de registro de la información (Arozarena *et al.*, 2016).

3.2.1. Pixel

Se denomina pixel como el elemento constitutivo más pequeño de cualquier imagen digital, misma que contiene información en un lugar especificado en la memoria del ordenador donde hay un número que proporciona la definición del color y del brillo de una parte de la imagen (Lacey, 2004).

3.2.2. Creación de pirámides

Para facilitar la velocidad de visualización de los documentos ráster como un número elevado de pixeles es posible crear una pirámide con distintos niveles de resolución (Moreno, 2008). Esto permite que, al abrir los documentos que los posee se muestre una capa de nivel de baja resolución mientras se prepara el conjunto de los datos (Moreno, 2008).

Por otro lado, al hacer zoom aparecerá el nivel de resolución adecuado sin necesidad de implicar el conjunto, ingresando en Arc Catalog por defecto una vez que se realiza la pre visualización de un ráster mayor de 1 024 * 1 024 celdas, el programa preguntará si se quiere iniciar el proceso de creación de pirámides, pudiéndose aplazar para más adelante o no (Moreno, 2008).

En el caso de aceptar se creará un nuevo documento RRD (reduced resolution dataset con extensión, rrd) conteniendo los niveles de menor resolución de la imagen con todas sus bandas si las tuviese, este documento ocupará sin comprimir aproximadamente un 8% de la imagen original pudiendo tener el documento comprimido un tamaño mayor que aquel (Moreno, 2008).

3.2.3. Bit

Se lo define como un dígito del sistema de numeración binario que puede adoptar valores de 0 o 1 (Sol, 2012).

3.3.Resolución que ofrecen los distintos sensores remotos

Entre una de las características clave que ofrecen los sensores remotos se puede mencionar a la capacidad de registrar discriminando información en detalle, a lo que se le denomina resolución de un sensor con la ayuda de estas, pueden evaluarse rangos de precisión con respecto a una serie de conceptos mismos que son de suma importancia en el análisis de imágenes espaciales (Chuvienco, 1995).

Este tipo de resoluciones son: espacial, radiométrica, espectral y temporal.

3.3.1. Resolución

El concepto de resolución mantiene una estrecha relación con la fotografía, sin embargo, para el propósito de esta investigación para imágenes satelitales se deberá tomar en cuenta la resolución espacial definida como el tamaño del elemento de tierra representado por un pixel individual generalmente determinado por el sistema óptico del sensor empleado para capturar datos (campo de visión) y la altura (Chuvienco, 1995).

3.3.1.1.Resolución radiométrica

Se la define como el número de bits que usan los distintos sensores para la cuantificación de la medida física de la radiancia cuyas unidades están dadas por ($W/m^2/\mu m/sr$) en otras palabras el número de niveles digitales que son empleados y que a su vez permiten la expresión de esta información (Gutiérrez & Muñoz, 2006). Cuanto mayor sea el número de bits reservados para el almacenaje del valor de un pixel, mayor será la resolución radiométrica (Gutiérrez & Muñoz, 2006).

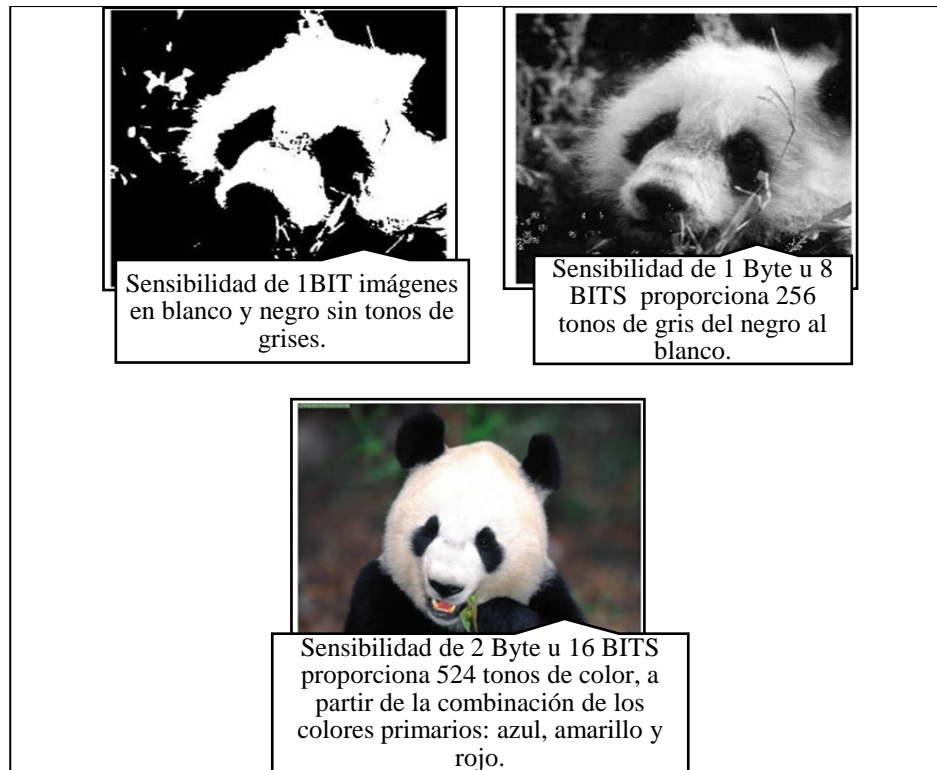


Figura 2. Sensibilidad de imágenes a diferentes bytes

Fuente: Instituto Nacional de Estadística y Geografía (2016). Disponible en: <http://www.inegi.org.mx/geo/contenidos/imgpercepcion/imgsatelite/resolucion.aspx>

3.3.1.2. Resolución espectral

Esta resolución muestra el número de ancho de las bandas espectrales que logra discriminar un sensor, cuando se proporcione un mayor número de bandas el sensor tendrá una resolución mayor (Gutiérrez & Muñoz, 2006).

Para el caso de una imagen en escala de grises esta posee una sola banda espectral mientras que para las imágenes de color se tienen tres bandas (rojo, verde y azul) (Vargas & Román-González, 2012).

3.3.1.3.Resolución espacial

Se define como la capacidad de un sistema en el que se puede distinguir los objetos dependiendo de su tamaño, en palabras sencillas es la distancia en la cual el tamaño del elemento más pequeño es perceptible en la imagen: tamaño del pixel que se encuentra en el terreno (Gutiérrez & Muñoz, 2006).

Este tipo de resolución en el trabajo condiciona la escala de este, además de la fiabilidad de interpretación, de modo que a menor tamaño de pixel mayor será la resolución espacial y con ello se obtendrá una visión más detallada de los objetos presentes en el terreno (Gutiérrez & Muñoz, 2006).




Figura 3. Sensores y satélites de teledetección consecuencias de la resolución espacial
Fuente: Geomática (2014). ADQUISICIÓN DE DATOS GEOMÁTICOS DESDE SATÉLITE. Disponible en <http://geomaticaysig.blogspot.com/2014/08/adquisicion-de-datos-geomaticos-desde.html>

En la Tabla 28 en el Anexo D se muestra una serie de sensores con su respectiva resolución espacial.

3.3.1.4. Resolución temporal

Hace referencia a la frecuencia de cobertura que es proporcionado por el sensor, es decir la periodicidad de la obtención de imágenes de la misma porción de la superficie terrestre permitiendo así la cuantificación de la capacidad presente en un sistema sensor para el registro de cambios temporales (José Sobrino, Raissouni, Oliosio, López, & Dempere, 2000). Este tipo de resolución depende tanto de las características orbitales de la plataforma entre las que se puede mencionar: altura, velocidad, inclinación y del diseño del sensor: ángulo de observación, abertura (José Sobrino *et al.*, 2000).

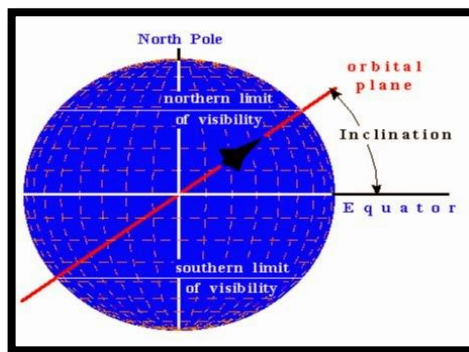


Figura 4. Resolución Temporal

Fuente: Geomática. (2014). Resolución temporal del satélite. Disponible en: <http://geomaticaysig.blogspot.com/2014/08/adquisicion-de-datos-geomaticos-desde.html>

3.4. Plataformas para descargar imágenes satelitales

Existen varias plataformas en la actualidad para descargar imágenes satelitales de acceso libre, gratuitas dependiendo del sensor a utilizar y la resolución de la imagen multiespectral.

Tabla 1. Plataformas de descarga de imágenes satelitales

Sensor	Plataformas de descarga
Landsat	- Servicio Geológico de Estados Unidos (usgsearthexplorer)
+TM	- Global Visualization Viewer (GloVis) - Servicio Geológico de Estados Unidos (usgsearthexplorer)
MODIS	- Level 1 and Atmosphere Archive and Distribution System Web Interface. (https://ladsweb.modaps.eosdis.nasa.gov)

Elaborado por: Torres N., Vivanco V. 2018

3.5. Sensores remotos utilizados en Teledetección

En la Tabla 30 del Anexo E se encuentra los sensores remotos más utilizados en la teledetección.

3.5.1. Landsat 7

Es uno de los satélites de la NASA enviado con la finalidad de producir un registro multiespectral sin interrupciones desde la superficie terrestre forma parte de un conjunto de satélites previamente enviados desde el año de 1972 hasta la actualidad, definiendo especial importancia en la actualización de los datos en forma periódica además de mantener una calibración precisa del instrumento, es ampliamente utilizado por gobiernos, entidades públicas, privadas y aplicaciones de seguridad nacional (National Aeronautics and Space Administration, 2016). En la Tabla 29 del Anexo E se encuentran las bandas espectrales que conforman al sensor “Landsat 7”.

3.5.2. Landsat 8

Es el octavo satélite remoto de Estados Unidos más actual lanzado el 11 de febrero de 2013, encontrándose hasta la actualidad. El satélite captura la información cada 16 días alrededor de las 10 de la mañana en el Ecuador (Vargas-Cuentas *et al.*, 2018). Este satélite está compuesto por 11 bandas satelitales entre las cuales 9 bandas son captadas por el sensor OLI y 2 bandas por el sensor TIRS, todas las especificaciones de las bandas se mencionan en la Tabla 8 (Vargas-Cuentas *et al.*, 2018). Las imágenes satelitales provenientes del satélite “Landsat 8” son de acceso libre y gratuitas, para su descarga se ingresa a la página web del Servicio Geológico de los Estados Unidos (Vargas-Cuentas *et al.*, 2018). En la Tabla 31 del Anexo F se detallan las bandas espectrales de Landsat 8 con sus respectivas longitudes de onda.

3.5.3. MODIS

MODIS (Moderate Resolution Imaging Spectroradiometer) es un instrumento lanzado en 1999, realiza la captura de datos de 36 bandas satelitales abarcando una gran cobertura de la superficie de la Tierra con resoluciones de 250, 500 m, 1 km dependiendo del producto ,generando productos con una alta resolución temporal, los cuales pueden ser utilizados para visualización de cambios en el ambiente (Xia *et al.*, 2018).

En la Tabla 32 del Anexo F se detallan las bandas espectrales de MODIS con sus respectivas longitudes de onda.

3.5.3.1.Principales características de productos MODIS

Existen en la actualidad varios productos entre los más importantes y más utilizados tenemos:

- MODIS Aerosol Product (MOD 04)

Es una imagen que captura el tamaño de un aerosol ambiental y su distribución sobre un cuerpo de agua, contando con una resolución espacial de 10 x 10 (Administración Nacional de la Aeronáutica, 2015c). Es un producto generado por un algoritmo basado en las bandas satelitales 1 a la 7 y 20 derivadas por las medidas del cielo, muy utilizado hoy día para investigaciones de aerosoles generados de manera antropogénica o de manera natural (Administración Nacional de la Aeronáutica, 2015c)

- MODIS Índices de vegetación (MOD 13)

Este tipo de producto se da cada 16 días, corregidas atmosféricamente basado en la reflectancia de las bandas satélites roja e infrarrojo cercano ,contando con una resolución de 250 metros; 500 metros; 0,05 Deg ,este producto se utiliza para observar las variaciones en la vegetación durante un periodo tiempo, realizar modelaciones de cobertura vegetal en la superficie terrestre (Administración Nacional de la Aeronáutica, 2015b).

- MODIS Temperatura y Emisividad de Superficie Terrestre (MOD 11)

Este producto proporciona la temperatura diurna, temperatura nocturna y emisividad, presentando a resoluciones espaciales de 500 m, 1 km, 0.05 Deg y 6 km, este producto es generado a partir de las bandas 31 y 32. Puede producirse errores dependiendo de la mayor resolución por la dificultad de visión (Administración Nacional de la Aeronáutica, 2015d).

- MODIS Reflectancia superficial (MOD 09)

Este producto está compuesto por las 7 bandas de reflectancia con una estimación de reflectancia medida desde el suelo, estas son corregidas para los aerosoles atmosféricos, cuenta con resoluciones de 500 m, 1 km y 0.05 Deg (Administración Nacional de la Aeronáutica, 2015a)

3.6. Correcciones de las imágenes

Existen una serie de tipos de correcciones que se pueden realizar a las diferentes imágenes satelitales con el objetivo de mejorar su resolución y corregir errores por defecto es el caso de la corrección radiométrica y atmosférica (Arango, Branch, & Botero, 2005).

3.6.1. Corrección topográfica

La corrección topográfica permite eliminar los efectos de las irregularidades presentes tanto en el terreno lejano y cercano de la estación de medición mediante la aplicación de los valores geofísicos observados (Álvarez Mendoza, 2014b; Cortés, 2000). Este tipo de correcciones se lo realizan sobre la imagen que posea una superior o similar escala en un modelo digital de elevación (Álvarez Mendoza, 2014; Cortés, 2000).

3.6.2. Corrección radiométrica

La corrección radiométrica es una técnica que permite modificar los niveles digitales originales, con el objetivo de aproximarlos a los que existiría en la imagen asumiendo una recepción ideal, disminuyendo factores tales como: la curvatura terrestre y relieve, imprecisiones del sensor, atenuación atmosférica o la dispersión de la energía reflejada, este tipo de corrección puede aplicarse a toda la imagen o una parte de ella (Álvarez Mendoza, 2014).

3.6.2.1. Restauración de líneas o píxeles perdidos

Producto del mal funcionamiento del sensor o la imagen, puede llevar a que aparezcan una serie de líneas o píxeles perdidos en forma de líneas anómalas (blancas o negras) y en otros casos como píxeles aislados de aspecto muy contrastado con los vecinos (Chuvieco, 1995). No se puede mejorar aquello que nunca se adquirió; razón por la cual las correcciones tienen por objetivo la mejora artificial de las imágenes y con ello proporcionar su interpretación (Chuvieco, 1995).

La manera en que se permite la estimación de los ND de los píxeles erróneos se fundamenta en los píxeles vecinos, el cual es un fenómeno de auto correlación espacial, gran cantidad de las variables presentes tienden a establecer una fuerte asociación en el espacio (Campbell, 1981; Cliff & Ord, 1973).

3.6.2.2. Bandeado

Este fenómeno es consecuencia de la mala calibración entre detectores y se ve reflejado en zonas de baja radiancia, se presenta en forma de una banda más oscura o clara respecto a las demás, para realizar la respectiva corrección se asume que, en el caso de no existir error, los detectores proporcionarían los respectivos histogramas mismos que serían similares entre sí y a su vez al histograma local de la imagen en la cual se está trabajando (Universidad de Murcia, 2003). Para ello se realiza el cálculo de los coeficientes a_k y b_k para la respectiva corrección lineal de los detectores (Universidad de Murcia, 2003).

$$b_k = s/s_k \quad \text{Ec. 1}$$

$$a_k = m - b_k m_k \quad \text{Ec. 2}$$

Donde:

m = Media

s = Desviación típica del conjunto de píxeles de la imagen

m_k y s_k = Media y desviación típica de los píxeles obtenidos por el detector

A continuación, se procede a recalcular el valor de los ND (Universidad de Murcia, 2003):

$$ND'_{i,j} = a_k + b_k ND_{i,j} \quad \text{Ec. 3}$$

Asumiendo que la línea i ha sido captada por el detector k .

3.6.3. Corrección geométrica

Las imágenes de teledetección no cumplen con las características geométricas ya que su sistema de proyección no es ortogonal paralelo sino más bien se trata de un sistema de proyección central y producto del uso de este se crean deformaciones propias (F. González, 2007) . La corrección geométrica tiene por objetivo la generación de una imagen que represente fielmente los aspectos espaciales de la escena misma desde el punto de vista geométrico para su posterior uso en cartografía, generalmente tiene lugar en dos etapas (F. González, 2007). En primer lugar, se elige una cuadrícula rectangular, que generalmente se basa en la cuadrícula del mapa relevante, y se establece un conjunto de puntos para representar los nuevos centros de píxeles, posteriormente , los nuevos valores de píxeles se calculan a partir de los originales para asociarlos con esos puntos, formando así una nueva imagen (F. González, 2007). En general, estos dos pasos tienen el efecto de

deformar la imagen para ajustarse a esta representación cartográfica y el proceso se conoce como reproyección, mientras que el cálculo de los nuevos valores de píxeles se llama remuestreo (F. González, 2007).

Este tipo de corrección se realiza mediante la aplicación de un polinomio con Z, dicho modelo polinómico a aplicarse es el siguiente (Chuvieco & Hantson, 2010):

$$x' = A + Bx + Cy + Dz + Ezx + Fzy \quad \text{Ec. 4}$$

$$y' = A' + B'x + C'y + D'z \quad \text{Ec. 5}$$

Donde (x', y') y (x, y) están dadas por las coordenadas de la imagen corregida y sin corregir.

3.6.4. Corrección atmosférica

Es un proceso aplicado a las imágenes digitales cuya finalidad es la eliminación tanto del efecto de aerosoles como de la radiancia intrínseca que ingresa en el sensor y producto de ello se evidencia en la imagen como resultado de la interacción del sensor con la atmósfera, con ello se pretende la eliminación del componente intrusivo de ésta (Aguilar Arias, Mora Zamora, & Vargas Bolaños, 2015).

Un enfoque particularmente potente es usar información derivada de imágenes para eliminar los efectos de la atmósfera, a menudo utilizando datos multilook o multiespectrales, estos enfoques son particularmente útiles para la corrección de datos térmicos para derivar la temperatura superficial (Jones, 2010).

El método multiespectral se usa ampliamente en sensores remotos ópticos, como el método de píxeles más oscuros, alternativamente llamado método de objetivo oscuro (DT)

o método de sustracción de objetos oscuros (DOS) (Jones, 2010). Este enfoque y sus desarrollos (Chávez, 1996; Moran, Slater, & Teillet, 1992; Wu, Wang, & Bauer, 2005) se basan en la suposición de que dentro de una imagen hay algunos píxeles en sombra completa, de modo que cualquier resplandor medido para estos píxeles debe ser atribuible a la atmósfera (Jones, 2010).

3.6.4.1. Corrección atmosférica para datos térmicos

3.6.4.1.1. Métodos de un solo canal

Estos son los únicos enfoques disponibles para muchos de los sensores con un sólo canal térmico, la técnica requiere información sobre la distribución del vapor de agua y la temperatura en la atmósfera (se puede suponer que los efectos atmosféricos de otros gases son constantes); esta información puede derivarse de instrumentos de sondeo vertical en satélites o de modelos de predicción meteorológica (Jones, 2010). La estimación precisa de la temperatura superficial depende de la precisión de las estimaciones de emisividad con errores (más bien conservadores) $\pm 0,025$ que conducen a un error de temperatura de ± 2 °C para las condiciones típicas de latitud media (Dash, Göttsche, Olesen, & Fischer, 2002).

3.6.4.2. Enfoque Multilook

Otra aproximación a la corrección atmosférica de las estimaciones remotas de la temperatura de la superficie, hace uso de mediciones casi simultáneas de la temperatura de la superficie en diferentes ángulos de observación y por lo tanto diferentes trayectorias a través de la atmósfera (Jones, 2010). Las observaciones pueden ser de diferentes satélites o de un solo satélite usando sensores como el Radiómetro de exploración Along Track (ATSR) en ERS y Envisat que tiene un escaneo cónico y así se observa una característica tanto en el nadir cercano (0-22 °) como en una dirección hacia adelante (hasta 55 °) casi

simultáneamente (Jones, 2010). Las ecuaciones empíricas pueden usarse para hacer uso de las dos temperaturas efectivas diferentes, medidas a través de dos distintas trayectorias de la atmósfera para estimar la temperatura "verdadera" de la superficie, aunque se debe tener en cuenta cualquier variación angular en la emisividad de la superficie (Jones, 2010).

3.6.4.3. Enfoque multiespectral

Las mediciones de temperatura también pueden hacer uso de la absorción diferencial de la radiación térmica por la atmósfera en diferentes bandas de ondas usando la técnica de ventana dividida (Jones, 2010). El enfoque general es derivar la temperatura de la superficie de la tierra a partir de combinaciones lineales de las temperaturas de brillo medidas en los diferentes canales utilizando coeficientes empíricos para establecer los efectos atmosféricos (Jones, 2010).

3.6.4.4. Estimación de emisividad

Todos los enfoques de estimación de la temperatura de la superficie terrestre descritos anteriormente requieren estimaciones precisas de la emisividad adecuada para la superficie de interés, se puede usar una gama de enfoques basados en diferentes suposiciones para estimar la emisividad, principalmente con el uso de datos visibles auxiliares (Jones, 2010). Quizás la aproximación más simple a la estimación de ϵ es hacer uso de la alta correlación entre el NDVI y la emisividad, con una vegetación densa que a menudo tiene una emisividad tan alta como 0,994; mientras que el suelo árido y seco puede tener una emisividad tan baja como 0,925 (Jones, 2010).

3.7. Índices espectrales

Se definen como nuevas variables generadas por combinaciones matemáticas de dos o más bandas originales y espectrales escogidas como un camino en el que el nuevo índice va a relatar con mayor claridad los parámetros biofísicos de interés (Jones, 2010).

El principio de derivar índices espectrales a partir de las medidas de dos longitudes de onda es ampliamente adoptado en teledetección, especialmente en el uso de índices de vegetación para estudiar la cobertura vegetal (Jones, 2010). El uso de solo dos bandas de ondas simplifica enormemente la interpretación de aquellos espectros que por lo demás son bastante complejos, originalmente concebidos como índices de banda ancha que podrían aplicarse a los canales espectrales bastante amplios disponibles, por ejemplo en satélites como “Landsat” con la disponibilidad cada vez mayor de instrumentos hiperespectrales, el principio se ha extendido cada vez más al desarrollo de índices de banda estrecha más específicos que pueden utilizarse para la detección y cuantificación no solo de la cubierta vegetal sino también de una amplia gama de constituyentes específicos de la hoja como: pigmentos, proteínas y contenido de agua (Jones, 2010, p. 53).

3.7.1. Índices de vegetación

Los índices de vegetación generalmente son medidas adimensionales, derivadas de datos radiométricos que se utilizan principalmente para indicar la cantidad de vegetación verde presente, la mayoría de los índices de vegetación se basan en el fuerte aumento de la reflectancia de la vegetación alrededor de 700 nm (el borde rojo), un cambio que es característico de la vegetación verde y no se encuentra en otras superficies naturales que muestran cambios de reflectancia relativamente lentos con la longitud de onda en esta región (Jones, 2010). Con el paso de los años, se han desarrollado muchos índices de

vegetación para explotar este fenómeno; concentrándose en los principios subyacentes que impulsan la elección del índice de vegetación, delineando solo algunos de los índices más populares (Jones, 2010,p.67).

3.7.1.1. Índice de Vegetación ajustado al suelo

Índice de vegetación ajustado al suelo aconsejado para laborar en zonas cuyas características preponderantes son semiáridas y en las cuales la intervención del suelo es importante, disminuyendo con ello la consecuencia de la reflectividad mediante la introducción del factor L (Huete, 1988).

$$SAVI = \left[\frac{(L_{NIR} - L_{RED})}{(L_{NIR} + R + L_{RED})} \right] (1 + L) \quad \text{Ec. 6}$$

Donde:

L_{NIR} = Infrarrojo cercano banda 4 en Landsat 7 y banda 5 en Landsat 8.

L_{RED} = Rojo visible de la banda 3 en Landsat 7 y banda 4 en Landsat 8.

L = Constante para ajustar la línea vegetación suelo al origen, equivalente a 0,5 recomendado para densidades intermedias (Chuvieco, 2006,p.83).

3.7.2. Temperatura de Brillo

La temperatura de brillo es una variable determinable con la aplicación de los sensores infrarrojos que se hallan presentes en los distintos satélites para el caso de estudio “Landsat 7”, su cálculo se realizará previa la corrección radiométrica y atmosférica de la banda térmica, con la obtención de este valor se realizará la comparación de esta temperatura a nivel de sensor (González & Ortiz, 2015).

$$T = \frac{K_2}{\ln\left(\frac{K_1}{CAT} + 1\right)} \quad \text{Ec. 7}$$

Donde:

CAT = Radiancia con corrección atmosférica

$K_1 = 666,09 \text{ watt/m}^2 * \mu\text{m}$ Constante de calibración

$K_2 = 1282,71 \text{ K}$ Constante de calibración

3.7.3. Índice de diferencia normalizada de suelos

Índice de diferencia normalizada de suelos ideado por (Roger y Kearney, 2004), en el que sobresalen las áreas construidas y en suelo desnudo debido a que estas superficies poseen la característica de ser más reflectivas en el L_{SWIR} que en el L_{NIR} (Rodríguez, Jaramillo, & Capote, 2010).

$$NSI = \frac{L_{SWIR} - L_{NIR}}{L_{SWIR} + L_{NIR}} \quad \text{Ec. 8}$$

Donde:

L_{NIR} = Infrarrojo cercano banda 4 en Landsat 7, banda 5 en Landsat 8 y banda 2 en MODIS.

L_{SWIR} = Infrarrojo de onda corta 1 banda 5 en Landsat 7, banda 6 en Landsat 8 y banda 5 en MODIS.

3.7.4. Índice de agua de diferencia normalizada

Índice de agua de diferencia normalizada se lo ocupó inicialmente para determinar la cantidad de agua en humedales (McFeeters, 1996). Para el cálculo de este índice se emplea las bandas longitud de onda infrarroja corta e infrarroja cercana de las imágenes de teledetección. Se lo usa en la determinación de cantidad de agua que presenta la distinta vegetación o nivel de saturación de humedad en el suelo (Bo-cai, 1996).

$$NDWI = \frac{L_{NIR} - L_{SWIR}}{L_{NIR} + L_{SWIR}} \quad \text{Ec. 9}$$

Donde:

L_{SWIR} = Banda 5 en Landsat 7 y MODIS, banda 6 en Landsat 8 (Álvarez Mendoza, 2014a).

L_{NIR} = Infrarrojo cercano banda 4 en Landsat 7, banda 5 en Landsat 8 y banda 2 en MODIS (Álvarez Mendoza, 2014a).

3.7.5. Índice de vegetación de diferencia normalizada

Definido como el índice de vegetación de diferencia normalizada surge a partir de los datos satelitales meteorológicos, se emplea para mostrar los cambios en la vegetación global (Yoram & Kaufman, 1992). Para su cálculo se parte de la diferencia entre el IR cercano, LNIR y el rojo Lred, radiaciones que serán reflejadas desde la superficie y transmitidas a través de la atmósfera (Yoram & Kaufman, 1992). El producto de esta diferencia se ve afectado por la existencia de vegetación, por cuanto la vegetación verde marca una disminución en la señal en el rojo producto de la absorción de la clorofila (Yoram & Kaufman, 1992).

$$NDVI = \frac{L_{NIR} - L_{RED}}{L_{NIR} + L_{RED}} \quad \text{Ec. 10}$$

Donde:

L_{NIR} = Infrarrojo cercano banda 4 en Landsat 7, banda 5 en Landsat 8 y banda 2 en MODIS.

L_{RED} = Rojo visible de la banda 3 en Landsat 7, banda 4 en Landsat 8 y banda 1 en MODIS.

3.8. Mínimos Cuadrados Parciales

Este método se aplica cuando se posee datos dimensionales y escasos. El objetivo de PLS es predecir un conjunto de variables de respuesta de un conjunto de variables predictoras (Mou *et al.*, 2017). Este modelo encuentra una serie de vectores de dirección que garantizan que la covarianza entre la respuesta y el componente ponderado alcance la correlación máxima y por pares del componente, pudiendo ser utilizado para numerosas aplicaciones para datos experimentales y no experimentales (Mou *et al.*, 2017). El método de mínimos cuadrados parciales se lo puede emplear bajo las siguientes condiciones entre las cuales tenemos (Mou *et al.*, 2017):

- Al existir una sola variable dependiente en los datos de estudio.
- Cuando el número de variables independientes exceden en número al de las variables dependientes de los datos de estudio.

Mediante este método se entenderá los cambios que induce $\text{inv}(X'X)$

$$y = x \cdot \text{Beta} + \text{Error} \quad \text{Ec. 11}$$

Donde:

$$\text{Beta} = \text{inv}(X'X) * X'Y$$

x = matriz de predicción

y = matriz de respuesta

Para que haya casos de multicolinealidad se debe descomponer en matrices ortogonales

$$x = TP \quad \text{Ec. 12}$$

3.9.Regresión GWR “Geographically weighted regression”

Se trata de un modelo local de regresión espacial el cual tiene presente de forma explícita la estructura espacial de los datos (García, 2016).



Figura 5. Gráficas de relación entre dos variables

Fuente: García, S (2016). Generalización de variables medioambientales mediante interpolación GIS. Disponible en http://oa.upm.es/39397/1/SARA_GARCIA_CONDADO.pdf

El término GWR la introdujeron (Brunsdon, Fotheringham, & Charlton, 1996) para tratar a una familia de modelos de regresión ajustados al espacio, en el cual es posible la observación de las variaciones espaciales de una serie de parámetros estimados con el objetivo de saber dónde se produce y cuánto influye este sobre una determinada variable explicativa sobre la dependiente. En esta serie de modelos se trata de ajustar tantas regresiones como observaciones a las que se denomina unidades espaciales que sean consideradas en el análisis, fundamentada en distance decay (el cual se resume en dar mayor peso a las observaciones que se hallan más próximas y menos a las que se encuentran más alejadas, con la aplicación de la función kernel con la finalidad de simular el efecto de caída con la distancia (S. García, 2016).

El uso GWR explora las relaciones existentes entre las variables dependientes y variables explicativas y si en estas se produce un cambio entre los lugares (Modenés & Villarraga, 2014).

En lugar de realizar la calibración de una única ecuación, lo que hace GWR es generar una ecuación de regresión para cada una de las observaciones que presumen una entrada en el modelo.

La ecuación genérica para GWR a la que se debe ajustar en cada una de las observaciones es la siguiente (S. García, 2016):

$$y_i = \beta_{0i} + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{ni} x_n + \varepsilon_i \quad () \quad \text{Ec. 13}$$

Donde:

i = Es la variable espacial del modelo al que corresponde las coordenadas geográficas (x, y) de cada localización (García, 2016).

y_i = Variable dependiente.

$\beta_{0i}, \beta_1, \beta_2$ = Coeficientes.

x_1, x_2 = Variables independientes/ explicativas.

ε_i = Error residuos.

Variable dependiente (y): es la variable que simboliza el proceso que se intenta modelar, predecir o entender (García, 2016).

Variables independientes/ explicativas (x): son las variables que se emplean para la modelación de las variables dependientes(García, 2016).

Coeficientes de regresión (β): valores calculados para cada una de las variables independientes y mediante estos se permite determinar la relación existente, en caso de ser positiva igualmente su coeficiente también será positivo y si la relación fuese negativa también lo sería su coeficiente (García, 2016). Si se presenta una relación

sólida, el coeficiente encontrado será relativamente grande en base a las unidades de la variable independiente a la cual se asocia mientras que las relaciones débiles se presentan cuando los coeficientes están próximos a cero (García, 2016).

β_0 : Se la define como la intercepción de la regresión y representa aquel valor que se espera para la variable dependiente cuando el valor de las variables explicativas es cero (García, 2016).

Residuos (ϵ): producto de las porciones sin explicación de la variable dependiente y en la ecuación de regresión se encuentra expresada en forma de error aleatorio. En una ecuación de regresión los valores que toman los residuos es la medida del ajuste del modelo el que también se considerarían un error del modelo (S. García, 2016).

3.9.1. Forma de trabajo de la regresión ponderada geográficamente

Como se mencionó en líneas anteriores el GWR formula una ecuación por separado de cada observación además de realizar la respectiva estimación de coeficientes de regresión, permitiendo con ello que los parámetros sufran una variación de forma continua en el espacio geográfico (García, 2016). Para la obtención de estos coeficientes en el modelo se calcula un conjunto de pesos que se presenta en forma de matriz de pesos por cada punto (w_{ij}) que se empleará en la ecuación para su calibración en las entidades muestrales (García, 2016). En el cálculo de pesos este tipo de modelo usa funciones de ponderación espacial tipo kernel (Fig.6), en la que se pondera con menor peso a las observaciones alejadas mientras a las cercanas con mayor peso (S. García, 2016).




Figura 6. Esquema de ponderación típica

Fuente: García, S (2016). Generalización de variables medioambientales mediante interpolación GIS. Disponible en http://oa.upm.es/39397/1/SARA_GARCIA_CONDADO.pdf

Donde:

Y = Punto de observaciones

X = Es el punto de regresión

H = Bandwidth ancho de banda o ventana

w_{ij} = Es el peso del punto muestral j en el punto de regresión i

d_{ij} = Es la distancia entre el punto muestral j en el punto de regresión i

La función kernel emplea como dato de entrada la distancia entre dos localizaciones i y j , en la que presenta un ancho de banda “ h ” mismo que establece el rango espacial que abarca el núcleo, entregando un peso entre las dos localizaciones que con respecto a la distancia es inversamente proporcional.

En GWR se usan dos tipos de funciones de kernel mismas que han sido ampliamente usadas:

La función fija o ancho de banda fijo “ h ” denominada también como fixed kernel misma que se emplea en el caso en la que el área de búsqueda permanece constante pero para el caso del número de las observaciones en la calibración de la ecuación varía (S. García, 2016).

La fórmula empleada es:

$$w_{ij} = e^{-\left(\frac{1}{2}\left(\frac{d_{ij}}{h}\right)^2\right)} \quad \text{Ec. 14}$$

Donde:

w_{ij} = Es el peso del punto muestral j en el punto de regresión i y este a su vez varía en función de la distancia d_{ij}

h = Ancho de la banda (bandwidth)




Figura 7. Esquema de la función de Kernel ancho de banda fijo para la búsqueda de vecindad.

Fuente: García, S (2016). Generalización de variables medioambientales mediante interpolación GIS. Disponible en http://oa.upm.es/39397/1/SARA_GARCIA_CONDADO.pdf

3.9.2. Ancho de banda variable “h” o adaptive distance kernel

A diferencia del anterior lo que permanecerá constante es el número de observaciones mientras que para el área de búsqueda variará la calibración de cada ecuación Figura 8. Siendo una técnica adecuada cuando se presenta una distribución varía en el espacio (S. García, 2016).

$$w_{ij} = 1 - \left(\frac{d_{ij}^2}{h^2}\right)^2 \quad \text{Ec. 15}$$

Donde (Garcia, 2016):

w_{ij} = Es el peso del punto muestral j en el punto de regresión i y este a su vez varía en función de la distancia d_{ij}

h = Ancho de la banda (bandwidth)

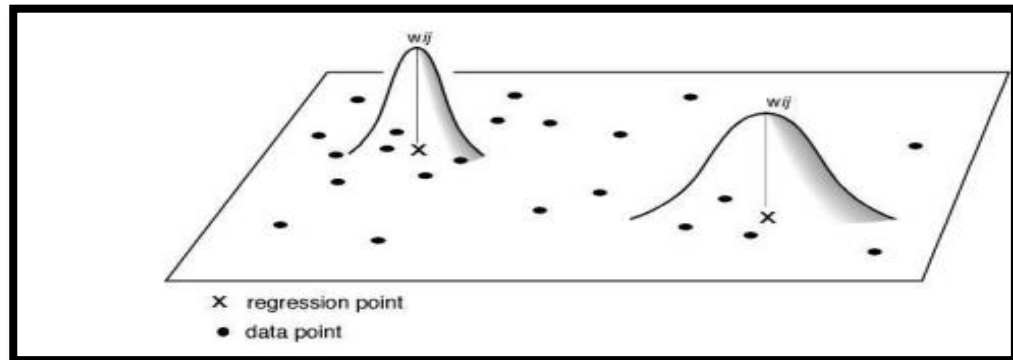


Figura 8. Esquema de la función kernel de tipo variable y búsqueda de vecindad mediante la aplicación de esta técnica.

Fuente: García, S (2016). Generalización de variables medioambientales mediante interpolación GIS. Disponible en http://oa.upm.es/39397/1/SARA_GARCIA_CONDADO.pdf

3.10. Regresión lineal generalizada

En este tipo de regresión se consideran los valores de la variable dependiente y que son obtenidos por combinación lineal de una o más variables explicativas y un término aleatorio (Hernández, 2007). El modelo de regresión lineal generalizada busca estudiar la asociación existente entre variables explicativas x_1, x_2, \dots, x_k ($k \geq 2$), estas a su vez pueden ser continuas o polinómicas y en algunos casos pueden presentarse como una mezcla de ambas. Este tipo de modelo busca la asociación que hay entre las variables x_1, x_2, \dots, x_k y una única variable dependiente y (Hernández, 2007).

Para realizar la estimación del modelo mediante esta técnica es necesario de n observaciones, con información de k variables independientes y de una variable dependiente y , misma que se considera consecuencia de las variables independientes. El modelo de regresión sólo emplea las observaciones que no tienen datos faltantes en las variables involucradas (Hernández, 2007).

El modelo teórico de regresión lineal generalizada se define como (De la Fuente, 2011):

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad \text{Ec. 16}$$

Donde:

x_{1i}, x_{2i} = Constantes conocidas.

β_0, β_1 = Parámetros del modelo.

y_i = Variable aleatoria observable.

ε_i = Variable aleatoria no correlacionada, con media cero y varianza común.

En forma matricial:

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & \dots & x_{k1} \\ 1 & x_{12} & \dots & x_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1n} & \dots & x_{kn} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

$$y = x\beta + \varepsilon \quad \text{Ec. 17}$$

Siendo x = Matriz del diseño.

Las hipótesis comunes en este tipo de regresión son (De la Fuente, 2011):

- Normalidad: $\varepsilon_i \in N(0, \sigma^2)$
- Linealidad: $E(\varepsilon_i) = 0$
- Homocedasticidad: $\text{Var}(\varepsilon_i) = 0$
- Independencia: ε_i son independientes $i = 1, 2, \dots, n$

4. MATERIALES Y MÉTODOS

En este capítulo se detallará los métodos y materiales mismos que fueron requeridos durante el desarrollo de la investigación. Entre ellos tenemos los siguientes índices espectrales: SAVI, NDVI, LST, NDWI y NSI calculados mediante las imágenes satelitales y datos de PM₁₀ proporcionados por la Secretaría del ambiente.

4.1. Materiales y Métodos

La metodología aplicada en la presente investigación (véase Figura 9), se fundamentó en el método determinado por (Álvarez Mendoza, 2014), donde se realizó la corrección atmosférica de cada una de las imágenes seleccionadas de los satélites “Landsat 7, 8” y “MODIS”. En el presente diagrama de flujo se recopila de forma específica cada uno de los pasos para lograr la concentración estimada de material particulado PM₁₀ y su posterior validación mediante la comparación con los datos provistos por las distintas estaciones de la REMMAQ ubicadas en distintas zonas del Distrito Metropolitano de Quito.

Como preámbulo se presentará una breve descripción de las características de las imágenes satelitales provenientes de los distintos sensores y la razón de su elección:

4.1.1. Landsat 7

Las imágenes que se usaron para la determinación de los índices espectrales fueron de nivel uno con una resolución espacial de 30 m y que cuentan con un total de ocho bandas (1-5 y 7), además incluyen corrección radiométrica, geométrica esta última se realiza por medio del Modelo de Elevación Digital (DEM) proveniente del SRTM (Shuttle Radar Topography Mission) y poseen una resolución de 90 m sumado a ello cuenta con puntos de control asegurando la calidad del producto, con el objetivo de eliminar el error de paralelismo del relieve topográfico (IGN, 2016; National Aeronautics and Space

Administration, 2016). Cabe destacar que las escenas provenientes de este sensor desde el año 2003 presentaron un fallo en el corrector de línea escaneada (SLC) (IGN, 2016; National Aeronautics and Space Administration, 2016).

4.1.2. Landsat 8

Las imágenes proporcionadas por el sensor (OLI y TIRS) de nivel uno consistieron en aquellos productos de datos que poseen correcciones geométricas aplicadas, proveniente de puntos de control (GCP) o la aplicación de posición integrada para brindar a la imagen una proyección cartográfica (Ariza Alexander, 2013)a. Además contienen corrección topográfica y constan de nueve bandas espectrales con resolución espacial de 30 m presentes en las bandas 1 a la 7 y 9 adicionalmente presentan dos bandas térmicas 10 y 11 con una resolución de 100 m que permitieron la obtención de temperaturas precisas en la superficie (Ariza A., 2013).

Además de considerarse las imágenes del nivel 2 mismas que son derivadas a partir de las imágenes de nivel 1, y en la que los datos de las observaciones poseen consistencia y continuidad además de registrarse los efectos producidos por el cambio climático adicional a ello poseen un alto nivel de reflectancia de superficie (Servicio Geológico de los Estados Unidos, 2018).

4.1.3. MODIS

Se empleó una serie de productos proporcionados por este sensor entre ellos se mencionará:

4.1.3.1.MOD09A1

Cuenta con una resolución espacial de 500 m y poseen un total de 1-7 bandas, mediante este tipo de imágenes que emplean un sistema de corrección fundamentado en el modelo de transferencia radiativa desarrollado por (Tanre et al., 1986) se buscó la estimación de la reflectancia (MAS, 2011).

4.1.3.2. MOD11A2

Estas imágenes pertenecen al nivel tres y brindan la temperatura de la superficie terrestre calculada mediante promedios de esta, durante ocho días por píxel en una cuadrícula de 1200 x 1200 km (Wan & Li, 1997)a. Estos promedios se obtienen a partir de LST MOD11A1 donde se toma el período de ocho días adicional a ello presentan ocho capas de observación y las bandas 31, 32. Se usa un algoritmo en la determinación de la emisividad al igual que en las temperaturas en un par de imágenes tanto diurnas y nocturnas en cielo despejado en las siete bandas del térmico e infrarrojo medio en las distintas coberturas de suelo (Wan & Li, 1997).

4.1.3.3. MOD13Q1

Estos datos presentaron una resolución espacial de 250 m catalogado como un producto de nivel 3 con proyección sinusoidal brindan tanto el NDVI como el EVI que son calculados mediante las reflectancias bidireccionales superficiales corregidas atmosféricamente y en las que se enmascara: sombras de nubes, agua, nubes y aerosoles pesados (Didan, University of Arizona, Sydney, & NASA, 2015).

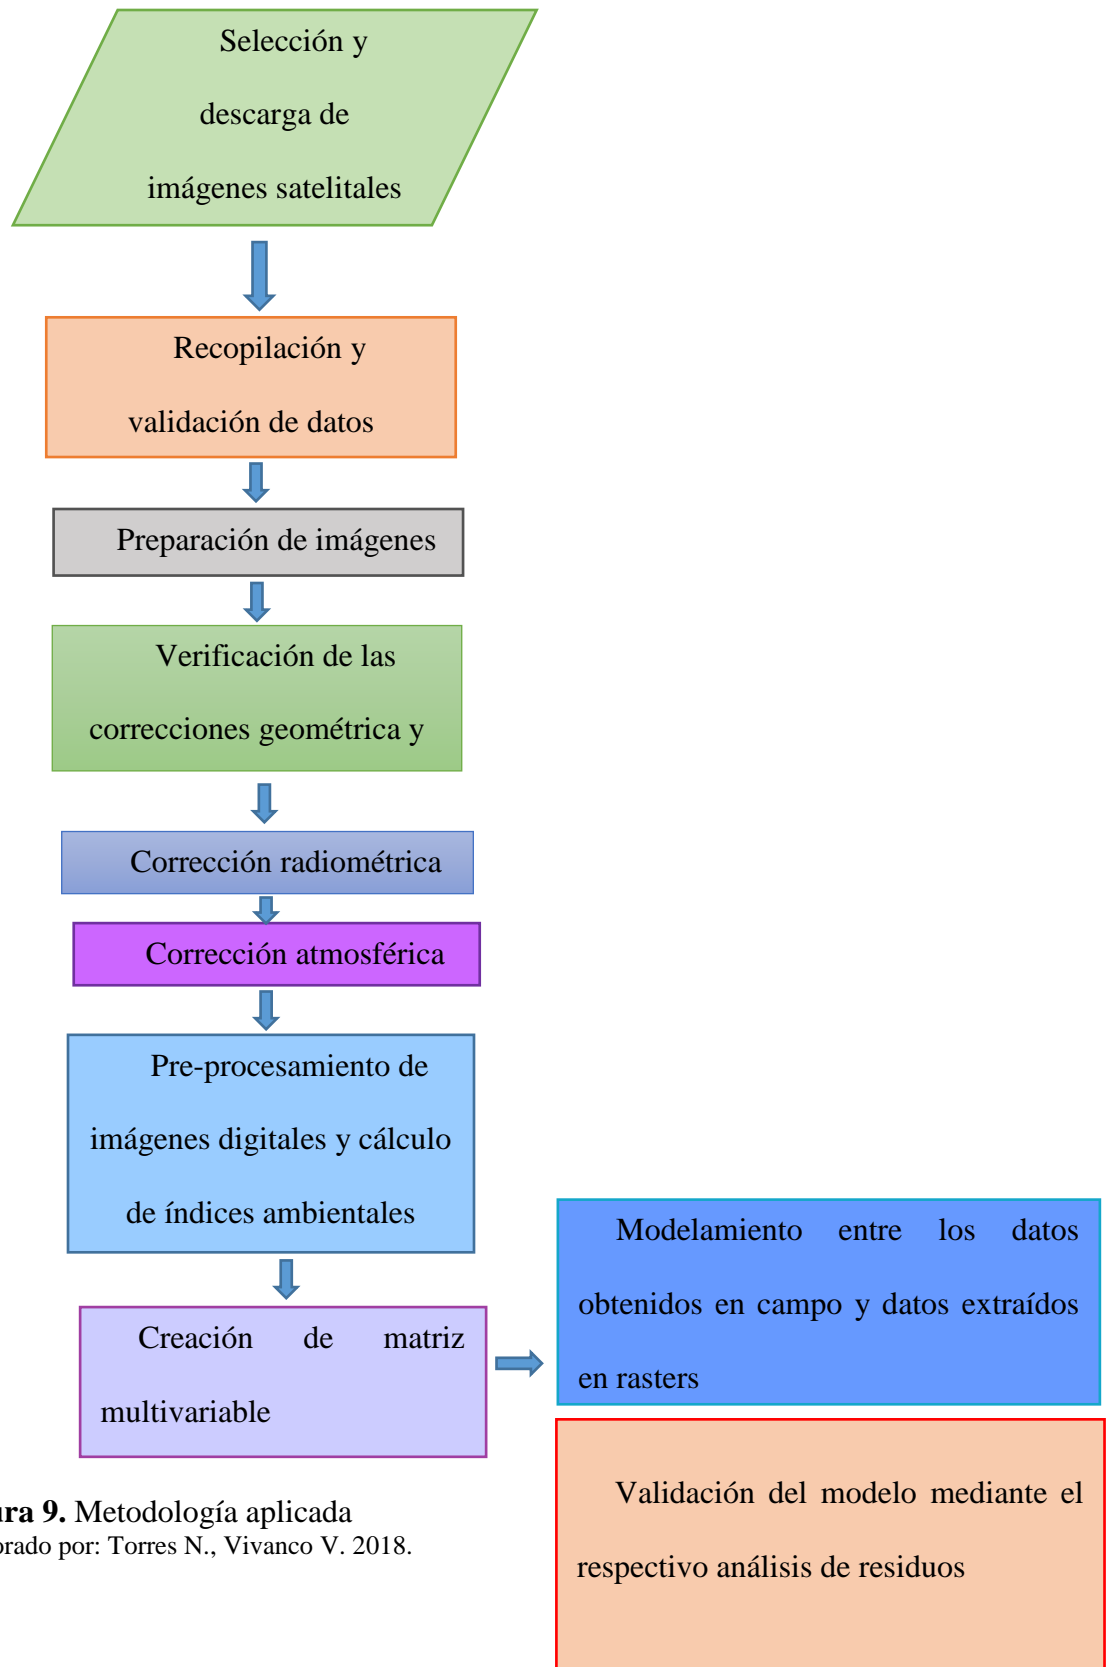


Figura 9. Metodología aplicada
 Elaborado por: Torres N., Vivanco V. 2018.

4.2. Área de Estudio

El Distrito Metropolitano de Quito (DMQ) se halla localizado en el centro norte de la provincia de Pichincha. Limita al norte con la provincia de Imbabura, al sur con los cantones Pedro Vicente Maldonado y San Miguel de los Bancos y con la provincia de Santo Domingo de los Tsáchilas. Su extensión territorial es de 4232 km^2 (Unidad de Investigación y Estudios de la Dirección de Planificación Territorial, MDMQ, 2009), comprende un mosaico: ecológico, paisajístico, cultural y geográfico, cuyas altitudes oscilan entre los 500 y 4 750 mm (Museo Ecuatoriano de Ciencias Naturales, 2010).

El presente proyecto consideró al área de influencia directa abarcó aquellos sectores donde se hallaron ubicadas tanto estaciones automáticas como pasivas de la Red de Monitoreo de la Calidad de aire, centrándose específicamente donde se efectuaron mediciones del contaminante criterio PM_{10} . De este modo, se incluyeron en el área de influencia indirecta un total de treinta y dos parroquias urbanas de Quito, parte de Rumiñahui y tres parroquias rurales.

4.3. Hardware empleado

El hardware que se utilizó para la generación del procesamiento digital de las imágenes provistas por los satélites Landsat 7, 8 y MODIS fue un computador con procesador Core i5.

4.4. Software empleado

En la presente investigación se empleó el software ENVI 5.0.3, mismo que permitió la realización del pre procesamiento de las imágenes satelitales LANDSAT 7, sumado a ello la herramienta de ArcGis 10.5 con el afán de obtener los diferentes índices ambientales y del contaminante en estudio de aquellos sectores estratégicos donde se hallan distribuidas las estaciones automáticas y pasivas de la REMMAQ. Tanto para la

generación y validación de los modelos propuestos se hizo uso del software R versión 3.4.4. Las licencias de ArcGis 10.5 fueron provistas por la Universidad Politécnica Salesiana.

4.5. Recopilación de información

Para el proyecto se emplearon las imágenes de los satélites: “Landsat 7”, “Landsat 8” y “MODIS” en el periodo 2003 al 2017 mismas que fueron obtenidas a partir de la base de datos existentes en la página web del Servicio Geológico de Estados Unidos (<https://earthexplorer.usgs.gov>) y como criterio de búsqueda la temporalidad de enero a diciembre además se tomó en cuenta que el porcentaje de nubosidad presente sea menor al 20% en el área de influencia y se procuró que las fechas coincidan, aquellas en las cuales no ocurría este hecho se consideró aquellas fechas cercanas, dichas imágenes cuentan con ortorrectificación además de corrección geométrica para su uso a escalas 1:50000. Adicional de las imágenes satelitales se utilizó datos de referencia de PM₁₀ obtenidos de las estaciones pasivas y automáticas de la REMMAQ cuyas coordenadas se especifican en la Tabla 26 del Anexo A. La información ambiental empleada fue obtenida a través de la Secretaría de Ambiente de Quito, específicamente de la página de la REMMAQ y en cuya base de datos se encontraban los valores diarios de cada año de las estaciones distribuidas en distintas zonas de la ciudad.

4.6. Preprocesamiento de imágenes satelitales

Una vez descargadas las imágenes satelitales de los sensores “Landsat 7,8” y “MODIS” es recomendable realizar las correcciones geométricas, topográficas, radiométricas y atmosféricas en el caso de que sea necesario. En esta investigación se procedió a realizar la corrección radiométrica únicamente para las imágenes del sensor “Landsat 7” Nivel 1 debido a problemas que se presentaron en las imágenes como pixeles distorsionados, incorrecta georreferenciación, altos porcentajes de nubosidad además de bandeo. Por otro lado, para las imágenes satelitales provenientes del Nivel 2 del sensor “Landsat 8” y del Nivel 1 del sensor “MODIS” no se necesitó aplicar un tratamiento previo antes de utilizarlas debido a que son productos correctamente calibrados en todas las bandas espectro magnéticas.

4.6.1. Corrección radiométrica

La corrección radiométrica es necesaria para convertir las imágenes a valores de reflectancia ayudando a un mejor procesamiento además de precisión, disminuyendo los efectos provocados por los procesos naturales de la Tierra. Para la corrección radiométrica mediante el software ENVI 5.0.3 se cargó cada uno de los metadatos entre los años 2003 al 2017 mediante el comando Geo TIFF with Metadata con el objetivo de poder visualizar el área de estudio. Adicional a esto se utilizó la herramienta “Radiometric Correction” donde se realizó la transformación de valores digitales a radiancia.

Por otro lado, para la calibración de la imagen se utilizó la herramienta Radiometric Calibration obteniéndose tanto la radiancia como la reflectancia aparente. Para el cálculo de la radiancia es necesario contar con los valores multiplicativos y aditivos de cada imagen satelital como lo muestra el Anexo B.

4.6.2. Corrección atmosférica

La corrección atmosférica es la más importante en una imagen en cuestión de disminución de aerosoles por la interacción del sensor con el aerosol en la atmósfera mediante la substracción del pixel de menor valor. Para realizar la respectiva corrección atmosférica establecida por Chávez se efectuaron con la herramienta Statistics obteniéndose el valor de las bandas multiespectrales a través de la visualización de los valores mínimos de los píxeles con estos se obtuvo el histograma y se eligió la opción Dark Substraction seleccionando la imagen a la que se le realizó la respectiva corrección para su análisis como lo indica el Anexo C.

4.7. Cálculo de los índices ambientales

El cálculo de los índices ambientales como ya se indicó en la investigación se realizó en ArcMap 10.5 con la ayuda de herramienta de Map Algebra con imágenes calibradas y con las correcciones adecuadas provenientes de los distintos sensores, donde se obtuvo el valor de cada indicador.

4.7.1. Índice diferencial de vegetación normalizado (NDVI)

Este indicador fue calculado mediante la herramienta de Map Algebra en Arcgis, utilizando las bandas de infrarrojo cercano y rojo, el número de la banda difiere según el sensor. Únicamente para el sensor MODIS la página del Servicio Geológico de Estados Unidos ofrece como producto el índice diferencial de vegetación normalizado ya calculado. Para el caso puntual del sensor MODIS se eligió las imágenes del nivel tres denominadas MOD13Q1 y en las que se procedió a multiplicar por un factor de escala 0,0001 debido a que los valores que se obtuvieron no se hallaron entre el rango -1 y 1. Cabe mencionar que este tipo de sensor realiza el cálculo de NDVI de acuerdo a (Tucker,

1979), fundamentado en el cociente normalizado de la banda del infrarrojo y la banda del rojo. Así se tiene (García-Mora & Mas, 2011):

$$NDVI = \frac{R_{IRC} - R_R}{R_{IRC} + R_R} = \frac{B_2 - B_1}{B_2 + B_1} \quad \text{Ec. 18}$$

Donde:

$R_{IRC} - R_R$ = Valores de reflectancia bidireccional de la superficie para las bandas infrarrojo cercano y rojo que pertenecen a las bandas B_2 y B_1 (García-Mora & Mas, 2011).

4.7.2. Índice diferencial de agua normalizado (NDWI)

Este índice expresa la cantidad de agua que existe en las hojas, mostrando los cambios provocados en la cobertura vegetal por factores externos, fundamentándose en las bandas NIR y SWIR. Para hallar el valor de este indicador se empleó la Ec.9, ingresando a la herramienta Raster Calculator en Arc Gis.

4.7.3. Índice de vegetación ajustado al suelo (SAVI)

Debido a que el área de estudio presentó una combinación entre cultivos y suelo árido en zonas como San Antonio, con este indicador se pretendió ignorar la reflectividad del suelo. Para ello se empleó la Ec. 6, se procedió como los demás indicadores considerando las bandas: NIR, R mediante el uso de Arc Gis 10.5 tanto en Landsat 7 y Landsat 8.

4.7.4. Índice de diferencia normalizada de Suelos (NSI)

Conocido como índice de diferencia normalizada de suelo para su cálculo se empleó la Ec.8 en la cual se realizó previamente la identificación de las bandas NIR y SWIR, permitiendo con este indicador la correcta diferenciación de zonas construidas.

4.7.5. Temperatura

En los siguientes esquemas se muestra de manera general los procedimientos para la obtención de temperaturas de superficie para las imágenes “Landsat 7”, “Landsat 8” TIR y OLI.

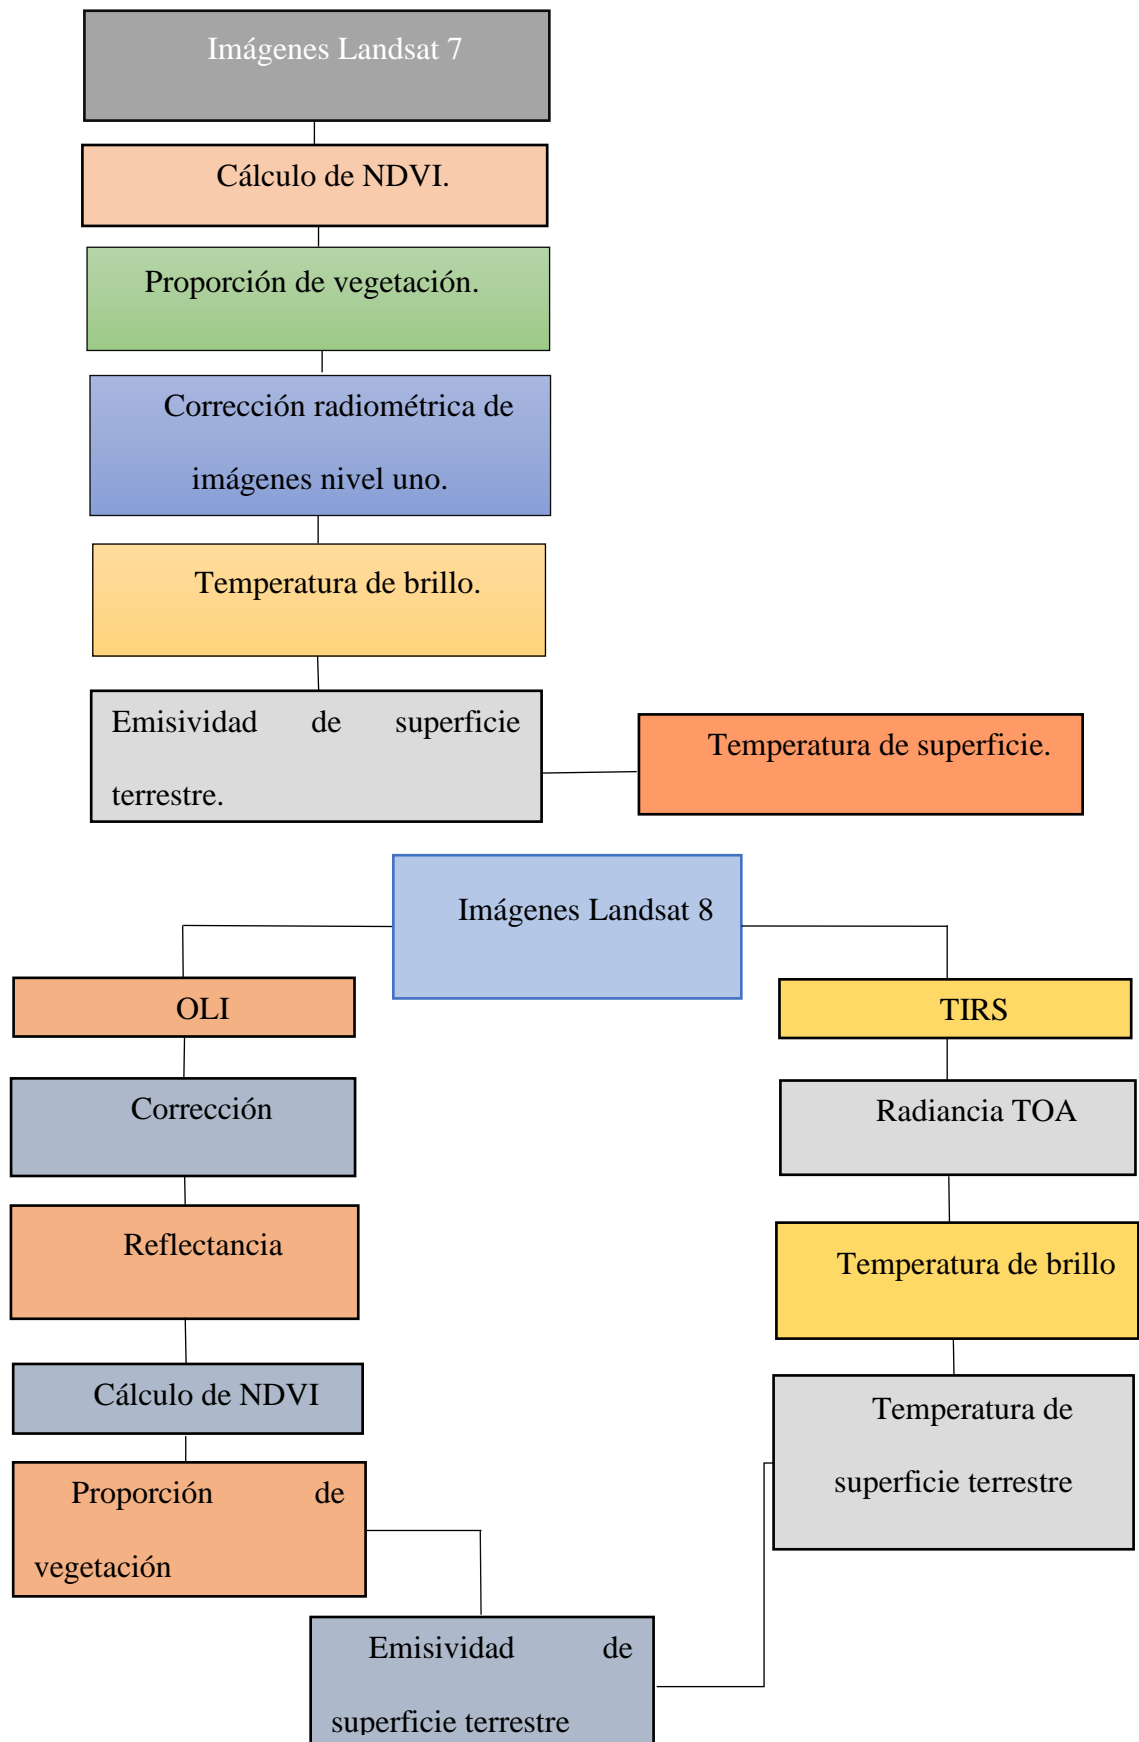


Figura 10. Metodología aplicada para obtención de temperatura
 Elaborado por: Torres N., Vivanco V., 2018

Como se pudo observar en los esquemas planteados para el tratamiento de las imágenes tanto para los sensores “Landsat 7” y “Landsat 8” se tratan de etapas similares para la generación de la temperatura de superficie salvo en la fase de obtención de temperatura de brillo en la que se diferencian y en la que se establecerá los respectivos procedimientos para ambos sensores. Razón por la cual se tratará al mismo tiempo tanto a “Landsat 7” y “Landsat 8” además de la obtención de este indicador en MODIS.

4.7.5.1. Proporción de vegetación

Es un indicador empleado en la estimación de la fracción de superficie cubierta por vegetación se empleó la siguiente fórmula (Skokovic et al., 2014):

$$P_V = \left(\frac{NDVI - NDVI_S}{NDVI_v - NDVI_S} \right)^2 \quad \text{Ec. 19}$$

Donde:

$$NDVI_S = 0,2$$

$$NDVI_v = 0,5$$

4.7.5.2. Emisividad de superficie terrestre

Para la determinación de la emisividad (LSE) se empleó un método semiempírico propuesto (Z. Li et al., 2013) el cual es una variación del NDVI^{THM} denotado también como SNDVI^{THM}, desarrollado por (J Sobrino et al., 2008), mismo que utilizó los umbrales de NDVI en la obtención de LSE en base a los distintos tipos de píxeles existentes en la imagen entre ellos se pueden mencionar: píxeles desnudos, píxeles totalmente cubiertos por vegetación y píxeles mixtos de acuerdo a la siguiente fórmula:

$$LSE = P_V * \varepsilon_V + (1 - P_V) * \varepsilon_S \quad \text{Ec. 20}$$

Donde:

P_V = Proporción de vegetación

ε_V = Emisividad promedio de la vegetación (0,98)

ε_S = Emisividad promedio del suelo (0,93)

4.7.6. Temperatura de brillo

Se la define como la temperatura aparente observada, suponiendo una emisividad superficial de 1,0 (es decir, como si el objeto se tratara de un cuerpo negro).

Para el caso del sensor “Landsat 7” se empleó la herramienta ENVI en la que se ingresó el metadato cargando las imágenes específicamente las bandas termales y posteriormente se realizó la corrección radiométrica para finalizar con la obtención de la temperatura de brillo si bien es cierto en líneas anteriores se mencionó que las imágenes contaban con correcciones geométricas y radiométricas éstas no se realizan para la banda térmica corroborándose al obtener valores bajo 0 K, razón por la cual fue de vital importancia este proceso para la obtención de este indicador. Además este sensor requiere de la aplicación de modelos de reflectancia y emisividad más complejos y sus imágenes no son muy usadas para el mapeo de temperaturas los problemas presentes en éste para la obtención de temperaturas son producto de la calibración (F. Li et al., 2004).

En el sensor “Landsat 8” se usó la Ec.7 en la que se identificó las variables existentes mediante la información proveniente en el metadato de cada imagen del presente estudio.

4.7.7. Temperatura de superficie

Para el cálculo de la LST en Landsat 7 se empleó previamente las imágenes en las que se obtuvo la temperatura de brillo mientras que para Landsat 8 se utilizó las bandas térmicas proporcionadas por los sensores TIRS mediante la siguiente ecuación:

$$LST = \frac{T_B}{1 + \left(\lambda \frac{T_B}{\rho}\right) \ln(LSE)} - 273,15^\circ\text{C} \quad \text{Ec. 21}$$

Donde:

T_B = Temperatura de brillo aparente en K

λ = Banda emitida B6C1 en Landsat 7; banda emitida B10 y B11 en Landsat 8 sin conversión a valores de radiancia

LSE = Emisividad de la superficie terrestre

$\rho = 14380 \mu\text{m} \cdot \text{K}$

Este último valor se obtiene de la siguiente ecuación:

$$P = h * \frac{c}{s} (1,438 * 10^{-2} mK) \quad \text{Ec. 22}$$

Donde:

h = Constante de Planck ($6,626 * 10^{-34} \text{Js}$)

c = Velocidad de la luz ($2,298 * 10^8 \text{ m/s}$)

s = Constante de Boltzman ($1,38 * 10^{-23} \text{ J/K}$)

Para el caso de MODIS existe un producto que permitió la obtención de LST denominado MOD11A2 por lo que fue necesario que al archivo se lo multiplique por un factor de escala 0,02 para la obtención de la temperatura en Kelvin y se restó el valor 273,15 para tener los valores en escala Celsius (Mart, 2010).

4.8. Creación de matriz con los indicadores medioambientales

Para modelar en R Studio se requiere la creación de una matriz multivariable para cada sensor con los promedios cuatrimestrales y semestrales de los parámetros calculados como PM₁₀, NDVI, NDWI, NSI, SAVI, LST, Latitud, Longitud de las estaciones automáticas y pasivas de la REMMAQ desde el año 2003 al 2017.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
1	ESTACION	LATITUD	LONGITUD	PM10	NDVI	NSI	SAVI	NDWI	LST	B1	B2	B3	B4	B5	YEAR	SEASON	SIGNIFICADO DE SEASON
2	BELISARIO	-0.18	-78.49	60.68	0.19	0.07	0.25	-0.02	33.3	1068	1424	1674	2436	2199	2003	3	Julio a Septiembre
3	BELISARIO	-0.18	-78.49	60.96	0.17	0.03	0.25	-1.05	31.1	1102	1344	1470	2069	2196	2003	4	Octubre a Diciembre
4	JPIPIAPA	-0.16	-78.48	68.31	0.15	0.02	0.23	-0.99	32.9	1110	1455	1621	2215	2311	2003	4	Octubre a Diciembre
5	LOS CHILLOS	-0.3	-78.46	31.73	0.29	0.09	0.43	-0.04	33.8	839	1159.5	1350	2433	2921.5	2003	3	Julio a Septiembre
6	LOS CHILLOS	-0.3	-78.46	20.55	0.5	-0.01	0.75	0	30.6	614	989	991	2903	2918	2003	4	Octubre a Diciembre
7	LOS CHILLOS	-0.3	-78.46	53.11	0.37	0.03	0.55	0.85	31.8	899.5	1178	1260.5	2732	2871.5	2004	1	Enero a Marzo
8	BELISARIO	-0.18	-78.49	54.72	0.33	0.07	0.33	0.51	28.4	863	1140.5	1282.5	1997	2392.5	2005	3	Julio a Septiembre
9	BELISARIO	-0.18	-78.49	115.99	0.25	0.05	0.38	0.78	31.6	904	1314	1523	2540	2801	2005	4	Octubre a Diciembre
10	COTOCOLLAO	-0.11	-78.5	96.89	0.18	0.06	0.27	0.31	33.5	847.33	1142.7	1311	1886	2141.3	2005	3	Julio a Septiembre
11	COTOCOLLAO	-0.11	-78.5	114.51	0.22	0.06	0.33	0.75	34.6	672	983	1131	1765	1985	2005	4	Octubre a Diciembre
12	GUAMANI	-0.33	-78.55	151.58	0.38	0.09	0.57	0.33	28.7	670.67	956	1045.3	2350	2821	2005	3	Julio a Septiembre
13	GUAMANI	-0.33	-78.55	116.36	0.4	0.1	0.59	0.85	31.7	534	781	845	1953	2401	2005	4	Octubre a Diciembre
14	JPIPIAPA	-0.16	-78.48	28.07	0.07	0.02	0.11	-0.01	34.3	1151	1487	1688.5	1977	2081	2005	3	Julio a Septiembre
15	JPIPIAPA	-0.16	-78.48	43.47	0.13	0.06	0.2	0.78	33.5	1063	1370	1532	2006	2265	2005	4	Octubre a Diciembre
16	LOS CHILLOS	-0.3	-78.46	20.34	0.31	0.07	0.46	-0.02	37	774.5	1059.5	1204	2285	2611	2005	3	Julio a Septiembre
17	LOS CHILLOS	-0.3	-78.46	46.13	0.46	0.03	0.69	0.7	32.8	607	903	969	2616	2765	2005	4	Octubre a Diciembre
18	CARAPUNGO	-0.098	-78.45	123.32	0.41	0.06	0.46	-0.01	33.8	927.4	1247	1379.5	2243	2536	2006	1	Enero a Marzo
19	CARAPUNGO	-0.098	-78.45	256.02	0.28	0.06	0.43	-0.02	32.4	661	981	1086	1945	2184	2006	2	Abril a Junio
20	EL CAMAL	-0.25	-78.51	82.42	0.09	0.04	0.13	-0.01	28.5	3334	3662	3737	4033	4291.5	2006	1	Enero a Marzo
21	EL CAMAL	-0.25	-78.51	88.22	0.18	0.06	0.27	-0.02	32.8	1047	1383	1561	2249	2518	2006	2	Abril a Junio
22	JPIPIAPA	-0.16	-78.48	41.79	0.31	0.05	0.46	-0.01	33	851.5	1126	1251.5	2441	2715.5	2006	1	Enero a Marzo
23	JPIPIAPA	-0.16	-78.48	93.9	0.09	0.04	0.14	-0.01	32.2	867	1148	1270	1526	1650	2006	2	Abril a Junio
24	CARAPUNGO	-0.098	-78.45	204.48	0.43	0.02	0.64	1.03	32	824	1192	1385	2310	3339	2007	1	Enero a Marzo
25	CARAPUNGO	-0.098	-78.45	104.16	0.23	0.06	0.35	0	34.4	905	1286	1471	2265	2683	2007	3	Julio a Septiembre
26	CARAPUNGO	-0.098	-78.45	183.83	0.41	0.04	0.67	1	31	655	1010	1182	2247	2958	2007	4	Octubre a Diciembre
27	EL CAMAL	-0.25	-78.51	7.39	0.15	0.04	0.22	1.11	34.9	1147	1467	1636	2195	2388	2007	1	Enero a Marzo
28	EL CAMAL	-0.25	-78.51	124.18	0.12	0.05	0.18	0.94	34.9	1106	1420	1597.5	2034	2221	2007	3	Julio a Septiembre

Figura 11. Matriz con parámetros medioambientales

Elaborado por: Torres N., Vivanco V., 2018

4.9. Modelos de predicción de PM₁₀

Para el modelamiento de PM₁₀ se utilizó los siguientes modelos como: regresión lineal generalizada y regresión geográficamente ponderada. El desarrollo de estos modelos se realizó en el software R Studio con la ayuda de la matriz multivariable para cada sensor, especificando como variable dependiente los datos de PM₁₀ proporcionado por la Secretaría del Ambiente de las estaciones de monitoreo de la REMMAQ y como variables independientes los indicadores ambientales, coordenadas latitud – longitud, además valores de las bandas espectrales como: BLUE, GREEN, RED, NIR, SWIR. La validación del modelo será aceptada siempre cuando el coeficiente de determinación “R² ajustado” y criterios de información posea una buena capacidad predictiva. A

continuación, se muestra el número de imágenes procesadas, el nivel, período de estudio y sensor utilizados para la generación de los Modelos:

Tabla 2. Resumen de imágenes procesadas para el presente estudio.

Sensor	Número de imágenes procesadas	Período de estudio	Nivel
Landsat 7	50	2003-2017	L1T
Landsat 8	37	2013-2017	L2T
MODIS	104	2003-2017	MOD09A1
	104	2003-2017	MOD11A2
	104	2003-2017	MOD13Q1

Elaborado por: Torres N., Vivanco V., 2018

5. RESULTADOS Y DISCUSIÓN

5.1. Sensor “Landsat 7”

5.1.1. Análisis de información de recopilada de PM₁₀

La información de la concentración de PM₁₀ observada en la Red de Monitoreo Atmosférico de Quito (REMMAQ) fue analizada durante los años 2003 al 2017, en los cuales se examinó la conducta del contaminante criterio descrito anteriormente. Se tomó en cuenta para el análisis las estaciones de monitoreo manual y semiautomático localizadas a lo largo de la ciudad en lugares como: Belisario, Carapungo, El Camal, Guamaní, Los Chillos, San Antonio y Tumbaco que son manejadas por la entidad antes mencionada.

En la Figura 12, se muestra el diagrama de cajas considerando los cuantiles: 0.25, 0.50 y 0.75; para los valores promedios diarios, recolectados en las estaciones de la REMMAQ, teniendo en cuenta datos recopilados en los meses de enero a diciembre, en los años desde el 2003 al 2017, donde LMP1 = 50µg/m³ este valor es el PM₁₀ límite máximo promedio para la Organización Mundial de la Salud (Organizacion Mundial de la Salud, 2018) y LMP2 = 100 µg/m³ es el PM₁₀ límite máximo promedio vigente en la Norma Ecuatoriana de la Calidad del Aire (Ministerio del Ambiente, 2011).




Figura 12. Diagrama de cajas del PM₁₀ por estación en la REMMAQ.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la siguiente tabla se detallan los valores de la mediana para cada estación de la REMMAQ.

Tabla 3. Valor de la mediana para cada estación de la REMMAQ.

Nombre de la estación	Mediana ($\mu\text{g}/\text{m}^3$)
Belisario	31,9
Carapungo	84,1
Cotocollao	33,8
El Camal	60,9
Guamaní	40,1
Jipijapa	58,8
Los Chillos	27,3
San Antonio	54,6

Tababela	35,8
Tumbaco	42,9

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Figura 12, se observa que en la mayoría de estaciones los valores promedios diarios de PM₁₀ exceden el LMP1, pero pocas sobrepasan el LMP2 y además se puede visualizar la presencia de puntos atípicos en todas las estaciones, excepto en la estación de Tababela. También se evidencia que para la estación de San Antonio hay una única observación de PM₁₀ para todo el periodo de estudio.

En la Tabla 3, podemos notar que en la estación Carapungo se presentó la concentración más alta de PM₁₀, con una mediana de 84.1 µg/m³, seguido de la estación El Camal con 60.9 µg/m³; mientras que los valores más bajos se localizan en la estación de Los Chillos con una concentración de 27.3 µg/m³.

5.1.2. Descripción de la data

Tabla 4. Descripción de los datos de investigación para el sensor “Landsat 7”

Variables	Mínimo	Máximo	Media	Desviación estándar
PM ₁₀	7,39	360,7	62,13	51,66
NDVI	-0,26	0,71	0,17	0,12
NDWI	-0,19	0,26	0,01	0,06
LST	-0,99	32,59	23,59	6,34
NSI	-0,49	0,19	-0,01	0,07
SAVI	-0,39	1,07	0,25	0,17
BAND_BLUE	353	13651,67	1541,94	1949,38

BAND_GREEN	528	10562	1675,66	1631,1
BAND_RED	524	13731,67	1886,04	1905,28
BAND_NIR	643	5720	2280,48	857,57
BAND_SWIR	506	8324	2228,79	823,21

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Se puede destacar en la Tabla 4 para el sensor “Landsat 7”, que la desviación estándar de la variable PM_{10} es alta a diferencia de las variables independientes: BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR y BAND_SWIR; la variabilidad de la variable PM_{10} se puede mitigar aplicando una transformación apropiada a los datos tal que permita reducir la varianza de los mismos y conservar sus propiedades y tendencia.

A continuación, se muestra el análisis gráfico de la variable dependiente (PM_{10}) con las variables independientes (NDVI, NSI, SAVI, LST, BAND_NIR, BAND_SWIR), con el objetivo de analizar el tipo de relación que guardan las variables independientes con respecto a la variable dependiente, así como su dispersión y significancia:




Figura 13. Gráficas de dispersión de la variable PM_{10} vs. NDVI, NDWI, LST, NSI, SAVI (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “Landsat 7”.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 14. Gráficas de dispersión de la variable PM_{10} vs. $BAND_NIR$, $BAND_SWIR$ (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “Landsat 7”.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

De acuerdo a la Figura 13 y 14 las variables independientes no tienen relación lineal con la variable dependiente y presentan mucha asimetría, por tanto, es conveniente transformar la variable dependiente antes de modelarla.

Un modelo puede ser lineal con respecto a los parámetros, aunque las variables no sean lineales o a éstas se aplica una transformación apropiada para que sean lineales. Existen distintas técnicas que pueden utilizarse cuando los datos se concentran en un extremo de la distribución y todos los valores son positivos, una de estas técnicas comúnmente utilizadas es la transformación logarítmica (Damodar, Gujarati, & Porter, 2010). Gracias al uso de ésta transformación se reduce la varianza y mejora la linealidad entre las variables independientes y la variable dependiente; es decir, comprime valores altos y riega los valores bajos (McCune & Grace, 2002).

La Tabla 5 muestra la correlación existente entre la variable dependiente (PM_{10}) con las variables independientes (NDVI, NSI, SAVI, LST, $BAND_BLUE$, $BAND_GREEN$, $BAND_RED$, $BAND_NIR$, $BAND_SWIR$) y la correlación existente entre la variable

dependiente transformada log (PM₁₀) con las variables independientes (NDVI, NSI, SAVI, LST, BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR).

Tabla 5. Correlación existente entre variables dependientes y variables independientes para el sensor “Landsat 7”.

Variables	Correlación de Pearson	Variables	Correlación de Pearson
PM ₁₀ con NDVI	-0,1702	log (PM ₁₀) con NDVI	-0,1907
PM ₁₀ con NDWI	-0,1966	log (PM ₁₀) con NDWI	-0,2301
PM ₁₀ con LST	0,0194	log (PM ₁₀) con LST	0,0367
PM ₁₀ con NSI	0,182	log (PM ₁₀) con NSI	0,201
PM ₁₀ con SAVI	-0,1701	log (PM ₁₀) con SAVI	-0,1911
PM ₁₀ con BAND_BLUE	-0,0263	log (PM ₁₀) con BAND_BLUE	0,0362
PM ₁₀ con BAND_RED	-0,0253	log (PM ₁₀) con BAND_RED	0,0366
PM ₁₀ con BAND_NIR	-0,075	log (PM ₁₀) con BAND_NIR	-0,088
PM ₁₀ con BAND_SWIR	-0,0241	log (PM ₁₀) con BAND_SWIR	0,0547
PM ₁₀ con BAND_GREEN	-0,0183	log (PM ₁₀) con BAND_GREEN	0,0338

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Al analizar el coeficiente de correlación existente se debe tener en cuenta (Martinez, Tuya, Martinez, Perez, & Canovas, 2009):

- Si $r=1$ muestra una correlación positiva perfecta mostrando una relación directa (Martínez *et al.*, 2009).
- Si $0 < r < 1$ indica correlación positiva (Martínez *et al.*, 2009).
- Si $r=0$ existe la ausencia de una relación lineal pero esta condición no denota que puedan existir relaciones no lineales entre las dos variables en cuestión (Martínez *et al.*, 2009).
- Si $-1 < r < 0$ se conserva una correlación negativa (Martínez *et al.*, 2009).
- Si $r = -1$ se trata de una correlación negativa denotando una relación inversa (Martínez *et al.*, 2009).

Se puede observar que la correlación entre las variables independientes (NDVI, NSI, SAVI, LST) con PM_{10} es cercana a cero. La correlación entre la variable dependiente transformada $\log(PM_{10})$ y las variables BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR si bien muestran valores de correlación bajos estas variables son independientes a diferencia de LST, NDVI, NDWI, SAVI las cuales dependen de las bandas. En la Figura 15 se evidencia la relación lineal existente.




Figura 15. Gráficas de dispersión, ajuste lineal y ancho de banda al 95% entre $\log(\text{PM}_{10})$ vs. BAND BLUE, RED, GREEN, SWIR, NIR sensor “Landsat 7”.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.1.3. Análisis de los modelos generados

En la fase preliminar se consideraron un total de cuatro modelos:

- Modelo 1, 2,3: Regresión lineal generalizado sin transformación logarítmica.
- Modelo 4: Regresión lineal considerando una transformación logarítmica a PM_{10} .
- Modelo 5: Regresión ponderada geográficamente global.
- Modelo 6: Regresión ponderada geográficamente sin datos atípicos.

5.1.3.1. Modelos 1, 2, 3: Regresión lineal generalizada sin transformación logarítmica sensor “Landsat 7”

En la obtención de los modelos GLM mediante el uso de imágenes satelitales provistas por los sensores en estudio se emplearon datos de campo cuatrimestrales de PM_{10} durante los años 2003-2017. En estos primeros tres modelos se realizó el análisis estadístico con 134 observaciones y 15 variables.

En la Tabla 6 se detallan las ecuaciones modeladas en R Studio con su respectivo análisis estadístico. Según Ngadi (et al., 2009), el coeficiente de R^2 mide la calidad de predicción del modelo. Por otro lado Akaike (1974, 1981, 1983), Sakamoto & Kitagawa (1987) se refieren al criterio de información de Akaike como un índice para comparar modelos según sus valores ajustados y reales. Penny, Kiebel, & Friston (2003) afirman que el criterio de información Bayesiano es una herramienta para evaluar cual de los modelos planteados es el que más se aproxima según la predicción.

Como se presenta en la Tabla 6, el R^2 de los modelos resultantes del Sensor “Landsat 7” se encuentran entre valores desde 0.6368 al 0.7373 lo cual es muy aceptable pues un valor óptimo de R^2 se considera cuando es cercano a uno. Posteriormente se analiza la calidad entre los modelos obtenidos , donde se expone los criterios de información de

Akaike y Bayesiano, donde el valor más bajo corresponde al mejor modelo. Según estos resultados, es evidente que el modelo que tiene mejor ajuste es la ecuación “3” al tener valores bajos de AIC , BIC y un R² ajustado de 0.69.

Tabla 6. Análisis estadístico de modelos resultantes del sensor satelital “Landsat 7”

Modelo	Ecuaciones	R ²	R ² Aj.	AIC	BIC
1	$PM_{10} = (14430) + (44,62 * Long) - (102,6 * NDVI) - (21,87 * NSI) + (115,3 * SAVI) - (0,139 * B1) + (0,215 * B2) - (0,06 * B4) + (0,03577 * B5) - (5,45 * AÑO - (4,51 * SEASON))$	0,77	0,73	596,45	623,9
2	$PM_{10} = (10740) - (303,3 * NDVI) + (196,3 * SAVI) - (0,18 * B1) + (0,23 * B2) - (0,0158 * B4) - (5,3 * AÑO) - (4,22 * SEASON)$	0,66	0,636	599,4	620,01
3	$PM_{10} = (11720) - (0,165 * B1) + (0,214 * B2) - (5,8 * AÑO) - (3,54 * SEASON)$	0,707	0,69	603,2	619,94

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Una vez obtenidos los tres modelos, al aplicar “GLM” para cada sensor, se procedió a realizar un análisis de varianza, con la finalidad de escoger el modelo final en base al test de Fisher. Es importante indicar que además de los tres modelos resultantes, se consideró un modelo lineal multivariable para efectuar el análisis de varianza en cada sensor satelital con el afán de realizar una comparación entre modelos ajustados.

Según Serrano (2003), menciona que el análisis de varianza es una herramienta clave para evaluar modelos entre si tomando en cuenta las varianzas muestrales. Una de las

recomendaciones que manifiesta (CRAN R Studio, 2016) es que cuando se tiene una distribución gaussiana de datos es conveniente aplicar un Test de Fisher debido a que los datos son cambiantes con el tiempo.

En la Tabla 7 se presenta el análisis de varianza donde el Modelo 3 tiene un test de Fisher de 0.02366 el cual es significativo pues es menor a 0.05 y menor en comparación al de los demás modelos. Por tanto, el Modelo 3 está bien ajustado.

Tabla 7. Análisis de varianza de 3 modelos generalizados lineales y modelo lineal multivariable para el sensor “Landsat 7”

	Modelos	Res.Df	RSS	Df	Sum of Sq	F	Pr (F)
	Modelo lineal multivariante	59	10240				
1	Modelo lineal generalizado 1	62	10876	-3	-636,08	1,221	0,3097
2	Modelo lineal generalizado 2	65	12296	-3	-1419,21	2,7256	0,05213
3	Modelo lineal generalizado 3	68	14062	-3	-1766,85	3,3932	0,02366

Elaborado por: Torres N., Vivanco V., 2018

A partir de los resultados estadísticos de las Tablas 6 y 7 se determinó los modelos finales para cada sensor, escogiendo el que cumple con el análisis de varianza, coeficiente de determinación ajustado R^2 , criterio de información de Akaike y criterio de información Bayesiano para el cálculo de PM_{10} en el Distrito Metropolitano de Quito.

El modelo final resultante para datos del sensor “Landsat 7”, se detalla a continuación:

$$\text{PM}_{10} \text{ LANDSAT } 7 = 11720 + (0,1655 * B1) - (0,2149 * B2) - (5.847) - (3,542 * \text{SEASON}) \quad \text{Ec. 23}$$

Donde:

PM_{10} = Estimación de concentración del material particulado ($\mu\text{g}/\text{m}^3$)

B1 = Banda espectral azul con longitud de onda (0,45-0,52) μm

B2 = Banda espectral verde con longitud de onda (0,52-0,60) μm

SEASON = Temporada cuatrimestral de adquisición de la imagen satelital (valor del 1-4)

5.1.3.1.1. Validación del modelo GLM

Para la validación del modelo se analizó el comportamiento de los residuos, con el fin de elegir el mejor modelo que se ajuste a los datos. Por lo tanto, se realizó gráficas de distribución de patrones y normalidad de residuos. En la Figura 16, se presentan los análisis de residuos del GLM. La gráfica “Residuals vs Fitted ” sirve para comprobar la suposición lineal de un patrón de variación (Minitab, 2017). A primera vista en las gráficas “Residuals vs Fitted” los residuos con los valores ajustados muestran un alto grado de correlación entre ellos, es importante indicar que en el modelo se ajustan una gran parte de los datos. Sin embargo, existen valores atípicos en la parte superior e inferior de la gráfica, por falta de homocedasticidad; que puede ser considerado como un error de medición en los datos.

La gráfica de Normal Q-Q, sirve para confirmar la suposición de normalidad de datos utilizando los residuos estandarizados (Clay, 2015). Como se puede visualizar en las Figura 16, se presenta el comportamiento de los datos del sensor “Landsat 7”, observándose claramente una tendencia lineal distribuyéndose normalmente. Por otra parte, se debe mencionar algunas variaciones en los extremos, tratándose de valores atípicos.

La gráfica Scale – Location, sirve para verificar homocedasticidad dentro de la distribución de datos de la regresión lineal; es decir, visualiza si los residuos varían a medida que se distribuyen (National Institute of Standards and Technology, 2015). En la Figura 16, se muestra la relación entre Scale – Location de todos los sensores, presentando una dispersión equilibrada de residuos entre ambos ejes, aquí es importante señalar que existen valores que se propagan a medida que la línea se hace curva.

La gráfica entre la relación Residuals vs Leverage, sirve para visualizar el grado de dependencia de los valores atípicos en las variables de la regresión y si es posible su eliminación para perfeccionamiento del modelo (Kim, 2015). El análisis entre Residuals vs Leverage para el modelo seleccionado se ilustra en la Figura 16.




Figura 16. Gráficas de análisis de residuos del modelo lineal generalizado seleccionado para el sensor “Landsat 7”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

A continuación, se muestran los mapas creados a partir del Modelo 1 desde 2013-2017:




Figura 17. Clasificación de PM₁₀ estimado para el año 2013.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 18. Clasificación de PM₁₀ estimado para el año 2015.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 19. Clasificación de PM₁₀ estimado para el año 2017.
Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)

5.1.3.2. Modelo 4, 5 y 6: Regresión ponderada geográficamente para el sensor “Landsat 7”

El Modelo 4 se plantea únicamente con propósitos de comparación, no se profundizará en sus coeficientes, pero si en su validación.

Para encontrar el Modelo 5, se extrajo los puntos atípicos que se detectaron en el diagrama de cajas de la Figura 12 y además se retira la estación San Antonio, pues tiene solo una observación en el período de estudio. Y se obtuvo lo siguiente:




Figura 20. Diagrama de cajas para PM₁₀ por estación.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Donde LMP1 y LMP2 representan el límite máximo promedio para la Organización Mundial de la Salud mientras que el segundo se trata de la Normativa Nacional vigente para PM₁₀ en $\mu\text{g}/\text{m}^3$.

El Modelo 5 y Modelo 6, se estimaron mediante una Regresión Ponderada Geográficamente, que encontraremos utilizando las siguientes funciones implementadas en R Studio versión 3.4.4, librería SPGWR.

5.1.3.2.1. Validación cruzada del ancho de banda para la Regresión Ponderada Geográficamente “Landsat 7”

5.1.3.2.1.1. Descripción

Encontraremos el ancho de banda para una regresión ponderada geográficamente, determinado al optimizar la Ec. 24 para la validación cruzada, el ancho de banda encontrado, minimiza el error cuadrático predicho para las regresiones geográficamente ponderadas.

5.1.3.2.1.2. Fórmula

gwr.sel (fórmula, datos, coordenadas, adapt, gweight, method, RMSE)

5.1.3.2.1.3. Argumentos

fórmula: $PM_{10} \sim NDVI$ Ec. 24

datos: La base de datos para el sensor “Landsat 7”, cuenta con 134 observaciones en las columnas: Estación, Longitud, Latitud, Año, Season, PM_{10} , NDWI, LST, NSI, SAVI; para el ancho de banda no se usa toda la base sino este subconjunto de variables.

coordenadas: Matriz de longitud y latitud.

adapt: Es un argumento booleano; si es VERDADERO, la función encuentra la proporción entre 0 y 1 de observaciones para incluir en el esquema de ponderación (k vecinos más cercanos), o FALSO, se deberá encontrar el ancho de banda global. En este caso se optó por la opción FALSO.

gweith: La función de ponderación geográfica puede ser: gwr. Gauss, gwr. gauss gwr.bisquare y se eligió por default la opción de gwr.gauss, mismo que devuelve un vector de ponderaciones usando el esquema gaussiano así:

$$w(g) = e^{-\left(\frac{d}{h}\right)^2} \quad \text{Ec. 25}$$

Donde:

d: Son las distancias euclidianas entre las observaciones. A este tipo de distancias se las define como la distancia en línea recta o la trayectoria más pequeña entre dos puntos (Krajewski, 2000).

h: Ancho de la banda.

method : Se tomó el argumento “cv” conocido como validación cruzada, otorgando una puntuación para un ancho de banda específico.

RMSE: El valor elegido fue FALSO de modo que correspondan a la suma de errores cuadrados de CV.

5.1.3.2.2. Modelo de Regresión Ponderada Geográficamente

5.1.3.2.2.1. Descripción

Esta función posee un enfoque básico de la regresión ponderada geográficamente, en la que se explora la no estacionariedad espacial para un determinado ancho de banda global y en base al esquema de ponderación en la Ec. 26

5.1.3.2.2.2. Fórmula

gwr (fórmula, datos, coordenadas, bandwidth,gweight, hatmatrix, predictions)

5.1.3.2.2.3. Argumentos

fórmula: $BAND_{RED} - BAND_{BLUE} - BAND_{GREEN} - BAND_{NIR} + BAND_{SWIR} - SEASON_2 - SEASON_3 - SEASON_4$ Ec. 26

datos: La base de datos para el sensor “Landsat 7” cuenta con 134 observaciones en las columnas: Estación, Longitud, Latitud, Año, Season, PM₁₀, BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR; para el modelo no se usó toda la base si no este subconjunto.

coordenadas: Matriz de longitud y latitud.

bandwith: El tamaño del ancho de la banda se calculó mediante gwr.sel descrito en líneas anteriores.

gweith: La función de ponderación geográfica puede ser: gwr. Gauss, gwr. Gauss, gwr.bisquare se eligió por defecto gwr.gauss .

hatmatrix: Calcula los diagramas de ponderación denominados como kernels equivalentes o efectivos, para una regresión local sin problemas y entrega diagramas de peso en lugar del ajuste. Se eligió por defecto VERDADERO.

predictions: Su uso radica en hacer predicciones de exclusión (cuando las ubicaciones de observación se utilizan para la predicción) y predicciones en un conjunto de datos de reserva (cuando las ubicaciones no observadas se utilizan para la predicción), por defecto se empleó la opción VERDADERO, en el que se otorgó puntos de ajuste de un Data Frame, devolviendo las predicciones de la regresión ponderada en los puntos de ajuste (Gollini, Charlon, Brunson, & Harris, 2015; Harris, Brunson, & Fotheringham, 2011; Harris, Fotheringham, Crespo, & Charlon, 2010; Harris & Juggins, 2011) .

De la Tabla 4 y las gráficas de la Figura 15 se determina que para plantear el modelo para el sensor “Landsat 7”, se tomará como variable dependiente a $\log(\text{PM}_{10})$ y como variables independientes a BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR donde: SEASON 1 (enero, febrero y marzo), SEASON 2 (abril, mayo y junio), SEASON 3 (julio, agosto y septiembre) y SEASON 4 (octubre, noviembre y diciembre), se considera a SEASON 1 como fijo en el modelo y a los demás valores se los representa como variables indicatrices definidas de la siguiente forma:

$$\text{Season 2} = \begin{cases} 1 & \text{si Season} \in (\text{abril, mayo y junio}) \\ 0 & \text{si no} \end{cases}$$

$$\text{Season 3} = \begin{cases} 1 & \text{si Season} \in (\text{julio, agosto y septiembre}) \\ 0 & \text{si no} \end{cases}$$

$$\text{Season 4} = \begin{cases} 1 & \text{si Season} \in (\text{octubre, noviembre y diciembre}) \\ 0 & \text{si no} \end{cases}$$

5.2. Resumen estadístico de los modelos planteados basados en el método de Regresión Geográficamente Ponderada

El resumen estadístico de los modelos planteados se presenta en la siguiente tabla:

Tabla 8. Comparación de los modelos generados para el sensor “Landsat 7”.

Modelo	Método	R ²	R ² Ajustado	RMSE	AIC
Regresión					
4	lineal	0,1261	0,0702	0,6332	277,8337
	Multivariada				
5	GWR con datos atípicos	0,6730	0,6721	0,3873	195,6218
6	GWR sin datos atípicos	0,6668	0,6660	0,3300	161,1963

Elaborado por: Torres N., Vivanco V., 2018

Para el método de regresión lineal multivariada con transformación logarítmica a PM₁₀, se tomó en cuenta el coeficiente de determinación R² y R² ajustado; éstos muestran la bondad de ajuste del modelo sin penalizar la inclusión de más variables explicativas y penalizándolas respectivamente. En este caso ambos coeficientes no fueron

estadísticamente representativos pues sus valores son menores a 0.5, lo cual muestra la baja bondad del ajuste del Modelo 4 para estimar el material particulado. También se empleó el Criterio de Información de Akaike, este describe la relación existente entre el sesgo y la varianza en la construcción del modelo y cuyo valor es mayor en comparación con los otros dos modelos generados; en este caso el criterio de AIC no es informativo pues los demás modelos son de diferente naturaleza. Los residuos del Modelo 4 no cumplen con los supuestos de validación como puede comprobarse en la siguiente Figura:




Figura 21. Gráficas de Residuales vs. Patrones ajustados y Normal Q-Q en “Landsat 7”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 22. Dispersión del material particulado observado y ajustado mediante una regresión lineal multivariada
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

La Figura 21 de residuos vs valores ajustados se empleó con el objetivo de verificar si éstos están correlacionados; es decir, si siguen patrones de no linealidad. Se puede

observar que los residuos siguen un patrón similar a una parábola, por tanto, los residuos si están correlacionados.

La Figura 22 de probabilidad normal de los residuos muestra los residuos vs sus valores esperados cuando la distribución es normal. Utilizamos la gráfica de probabilidad normal de los residuos para verificar el supuesto de que los residuos están distribuidos normalmente; la gráfica de probabilidad normal de los residuos debe seguir aproximadamente una línea recta, lo cual no ocurre para los residuos en los extremos.

Además, en la Figura 22 se muestra la gráfica del PM_{10} observado y ajustado mediante el modelo de regresión lineal multivariada, se puede verificar que las observaciones de PM_{10} predichas por el Modelo 2 no se ajustan a los valores observados del PM_{10} ; razón por la cual no resulta útil la aplicación de este modelo para el caso de estudio.

Con la finalidad de brindar un mayor ajuste estadístico se optó por retirar los puntos atípicos presentes en la investigación, véase Figura 20 mediante el ajuste por regresión ponderada geográficamente para el sensor “Landsat 7” sin datos atípicos y sin considerar la estación de San Antonio se obtuvo el Modelo 3 con un coeficiente de determinación R^2 de 0.6668, R^2 ajustado es de 0.6660 y el Criterio de Información de Akaike es de 161.1963. Los valores de los criterios son estadísticamente significativos pues son mayores a 0.5; por tanto, el Modelo 3 es mejor en comparación al Modelo 2. El Modelo ajusta un GWR a todos los datos, la calidad es similar con diferencias despreciables para el valor de estos indicadores de calidad. Se decide por tanto elegir el Modelo 3 como el mejor para estimar el contaminante en el Distrito Metropolitano de Quito, debido a que eliminar los puntos atípicos y la Estación de San Antonio se constituye como una reducción del área de estudio; mientras lo recomendable sería ampliarla y además

conservar los puntos detectados como atípicos ya que éstos pueden ser producto de un error de medición o eventos fortuitos relacionados con el PM_{10} .

En el ajuste del Modelo 4 para el sensor “Landsat 7” se obtuvo un coeficiente de determinación R^2 de 0.6730, R^2 ajustado de 0.6721 y el Criterio de Información de Akaike de 195.6218 por tanto este el modelo tiene el mejor ajuste. A continuación, se presenta el resumen estadístico de sus coeficientes en la Tabla 9, Ec.27 y el análisis de varianza en la Tabla 10:

Tabla 9. Resumen de la Regresión Ponderada Geográficamente del Modelo 6 para el sensor “Landsat 7”.

	Mínimo	Cuartil 1	Mediana	Cuartil 3	Máximo	Global
Intercepto	-1,4414	2,7708	3,5207	4,5577	8,4404	3,5776
BAND _{BLUE}	-0,0052	-0,0043	0,0001	0,0009	0,0175	-0,0014
BAND _{GREEN}	-0,0148	-0,0066	-0,0005	$5,67 * 10^{-5}$	0,0010	0,0000
BAND _{RED}	-0,0135	-0,0008	0,0020	0,0048	0,0057	0,0015
BAND _{NIR}	-0,0024	-0,0016	-0,0006	$-7,9 * 10^{-5}$	0,0061	-0,0003
BAND _{SWIR}	-0,0027	$-9,3 * 10^{-5}$	0,0002	0,0018	0,0036	0,0002

SEASON ₂	-1,5279	-0,9034	-0,4035	0,2685	0,9660	-0,3366
SEASON ₃	-1,3085	-0,5079	-0,2335	0,3855	2,9618	-0,1615
SEASON ₄	-1,9705	-0,0001	0,0515	0,1097	1,6622	-0,0046

Número de datos: 134 observaciones

Sigma: 0,5697675

AIC: 195,6218

R^2 : 0,6730619

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Ecuación de GWR para el sensor “Landsat 7”:

$$\begin{aligned} \log(PM_{10}) = & 3,57759 - 0,00141 BAND_{BLUE} - 0,00001 BAND_{GREEN} + \\ & 0,00147 BAND_{RED} - 0,00030 BAND_{NIR} + 0,00024 BAND_{SWIR} - \\ & 0,33657 SEASON_2 - 0,16146 SEASON_3 - 0,00459 SEASON_4 \quad \text{Ec. 27} \end{aligned}$$

Donde:

PM_{10} = Estimación de concentración del material particulado ($\mu\text{g}/\text{m}^3$)

$BAND_{BLUE}$ = Banda espectral azul con longitud de onda (0,45-0,52) μm

$BAND_{GREEN}$ = Banda espectral verde con longitud de onda (0,52-0,60) μm

$BAND_{RED}$ = Banda espectral roja con longitud de onda (0,63-0,90) μm

$BAND_{NIR}$ = Banda espectral infrarroja cercana con longitud de onda (0,76-0,90) μm

$BAND_{SWIR}$ = Banda espectral infrarroja de onda corta con longitud de onda

$SEASON_2$ = Temporada correspondiente a los meses (abril, mayo y junio)

$SEASON_3$ = Temporada correspondiente a los meses (julio, agosto y septiembre)

$SEASON_4$ = Temporada correspondiente a los meses (octubre, noviembre y diciembre)

Tabla 10. Análisis de varianza del Modelo 6 para el sensor “Landsat 7”

	Grados de libertad	Suma de cuadrados	Error cuadrático medio	F- valor
OLS Residuos	9,000	53,737		
GWR ajustado	63,07	33,632	0,53325	
GWR Residuos	61,93	20,104	0,32464	1,6426

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Se observa en la Figura 23 que los valores ajustados del Modelo 6 se ajustan de mejor manera a los valores reales del contaminante criterio.



Figura 23. Dispersión de PM₁₀ observado y estimado mediante GWR.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.2.1. Validación del Modelo 6

En el Modelo 6 para verificar el supuesto de que los residuos no están correlacionados y que tienen varianza constante se utiliza la Figura 24 de Residuos vs.

Ajustados. Lo ideal es que los puntos se ubiquen aleatoriamente a ambos lados del cero, con patrones no detectables, lo cual podemos verificar en la siguiente gráfica:




Figura 24. Dispersión de los residuos del Modelo 6
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 25. Ajuste Q-Q normal e histograma de ajuste normal de los residuos con un intervalo de confianza al 99% sensor “Landsat 7”
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Al observar la Figura 25 de ajuste Q-Q se puede notar que la mayoría de los puntos se encuentran localizados cercanos a la línea recta de distribución normal, aunque en el extremo superior derecho hay puntos atípicos provenientes de las observaciones de PM_{10} que eran puntos atípicos; por tanto, los residuos siguen una distribución normal.

En el histograma se evidencia que los residuos estandarizados tienen la forma de una Campana de Gauss con media igual a $3.67008e-17$ y desviación estándar igual a 0.63; por tanto, la media de los residuos es aproximadamente cero y debido a los puntos atípicos la desviación estándar está cercana a uno. Se puede concluir que los residuos siguen una distribución normal.

A continuación, se visualizan los mapas obtenidos mediante el ajuste por el Modelo 6:




Figura 26. Clasificación de PM₁₀ estimado para el año 2013.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 27. Clasificación de PM₁₀ estimado para el año 2015.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 28. Clasificación de PM₁₀ estimado para el año 2017.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)

5.3. Sensor “Landsat 8”

5.3.1. Análisis de información recopilada de PM₁₀

En la Figura 29, se muestra el diagrama de cajas obtenido a partir de los cuantiles: 0.25, 0.50 y 0.75 para los valores promedios diarios recolectados en las estaciones de la REMMAQ. Donde LMP1 = 50 $\mu\text{g}/\text{m}^3$ es el PM₁₀ límite máximo promedio para la (Organizacion Mundial de la Salud, 2018) y LMP2 = 100 $\mu\text{g}/\text{m}^3$ es el PM₁₀ límite máximo promedio vigente en la Norma Ecuatoriana de la Calidad del Aire (Ministerio del Ambiente, 2011)




Figura 29. Diagrama de cajas del PM₁₀ por estación en la REMMAQ.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Figura 29 se observa que en la mayoría de las estaciones los valores promedios diarios de PM₁₀ exceden el LMP1, mientras que ninguna estación sobrepasa el LMP2 y además se evidencia la presencia de puntos atípicos en las estaciones de Tababela, Los Chillos y Jipijapa.

5.3.2. Descripción de la data

Tabla 11. Descripción de los datos de investigación para el sensor “Landsat 8”

Variables	Mínimo	Máximo	Media	Desviación estándar
PM ₁₀	8,28	87,59	39,23	15,35
NDVI	0,04	0,65	0,23	0,13
NDWI	-0,13	0,21	0,02	0,07
LST	-4,61	32,48	25,55	5,54
NSI	-0,39	0,13	-0,02	0,07
SAVI	0,03	0,98	0,35	0,19
BAND_BLUE	290,5	4997,33	980,77	687,5
BAND_GREEN	361	5304,33	1253,03	676,04
BAND_RED	317	5555	1362,14	698,74
BAND_NIR	343	5878	2188,98	739,99
BAND_SWIR	296	5316,67	2118,75	685,25

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Tabla 11 para el sensor “Landsat 8” se destaca que la desviación estándar de la variable PM₁₀ es alta al ser comparada con las variables independientes BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR. La existencia de variabilidad en PM₁₀ se mitigó mediante la aplicación de una transformación a los datos, con lo cual se logró la reducción de la varianza; además, se conserva sus propiedades y tendencia.

Posteriormente en la Figura 30 y 31 se visualiza la variable explicativa PM₁₀ con respecto a las variables independientes (NDVI, NSI, SAVI, LST, BAND_BLUE,

BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR) con el fin de analizar la relación y tendencia existente entre las variables de estudio mediante un gráfico de dispersión.




Figura 30. Gráficas de dispersión de la variable PM₁₀ vs. NDVI, NDWI, LST, NSI, SAVI (ajuste de regresión polinomial local) con un intervalo de confianza del 95% para el sensor “Landsat 8”.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 31. Gráficas de dispersión de la variable PM_{10} vs. $BAND_BLUE$, $BAND_GREEN$, $BAND_RED$, $BAND_NIR$, $BAND_SWIR$ (ajuste de regresión polinomial local) con un intervalo de confianza del 95% para el sensor “Landsat 8”
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Tabla 12 se muestra la correlación entre la variable dependiente (PM_{10}) con las variables independientes (NDVI, NSI, SAVI, LST, $BAND_BLUE$, $BAND_GREEN$,

BAND_RED, BAND_NIR, BAND_SWIR) y la correlación existente entre la variable transformada log (PM₁₀) con las variables independientes (NDVI, NSI, SAVI, LST, BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR, BAND_SWIR).

Tabla 12. Correlación existente entre variables dependientes y variables independientes para el sensor “Landsat 8”.

Variables	Correlación de Pearson	Variables	Correlación de Pearson
PM ₁₀ con NDVI	-0,3845	log (PM ₁₀) con NDVI	-0,3379
PM ₁₀ con NDWI	-0,3038	log (PM ₁₀) con NDWI	-0,3118
PM ₁₀ con LST	-0,0803	log (PM ₁₀) con LST	-0,0653
PM ₁₀ con NSI	0,2703	log (PM ₁₀) con NSI	0,2457
PM ₁₀ con SAVI	-0,415	log (PM ₁₀) con SAVI	-0,3665
PM ₁₀ con BAND_BLUE	0,2796	log (PM ₁₀) con BAND_BLUE	0,2911
PM ₁₀ con BAND_RED	0,301	log (PM ₁₀) con BAND_RED	0,3356
PM ₁₀ con BAND_NIR	0,1181	log (PM ₁₀) con BAND_NIR	0,1212
PM ₁₀ con BAND_SWIR	0,2332	log (PM ₁₀) con BAND_SWIR	0,2416
PM ₁₀ con BAND_GREEN	0,2732	log (PM ₁₀) con BAND_GREEN	0,29

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Las variables independientes: NDWI, NDVI, SAVI, NSI no se consideran porque son calculadas a partir de las bandas. La correlación existente entre log (PM₁₀) y las variables: BAND_BLUE, BAND_GREEN, BAND_RED, BAND_NIR* BAND_SWIR es mayor

comparada con la correlación para la variable PM_{10} sin transformar, tal como lo muestran la Figura 32.




Figura 32. Gráficas de dispersión, ajuste lineal y ancho de banda al 95% entre $\log(PM_{10})$ vs. (BAND BLUE, RED, GREEN, NIR * SWIR) sensor “Landsat 8”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.3.3. Análisis de los modelos generados para el sensor "Landsat 8"

En la fase preliminar se consideraron cinco modelos que se describen en las líneas siguientes:

- Modelo 7, 8, 9: Regresión lineal generalizada sin transformación logarítmica.
- Modelo 10: Regresión lineal considerando una transformación logarítmica a PM_{10} .
- Modelo 11: Regresión ponderada geográficamente.

5.3.3.1. Modelo 7, 8, 9: Regresión lineal generalizada sin transformación

logarítmica sensor “Landsat 8”.

Para la estimación de los modelos se ajustaron 108 observaciones tomadas a partir de imágenes satelitales provistas por el sensor de estudio en periodos cuatrimestrales durante los años 2003-2017.

En la Tabla 13 se detalla los modelos obtenidos para el sensor “Landsat 8”, los cuales evidencian excelentes resultados estadísticos tanto en R^2 , AIC y BIC; donde predomina el Modelo 8 ya que presenta valores bajos de AIC, BIC y un R^2 mayor en comparación a los demás modelos.

Tabla 13. Análisis estadístico de modelos resultantes para el sensor satelital “Landsat 8”

Modelo	Ecuaciones	R^2	R^2 Aj.	AIC	BIC
7	$PM_{10} = - (31,56) + (111,4*NDVI) - (0,03*B1) + (0,089*B3) - (0,019*B4) - (5,42*SEASON2)$	0,693	0,668	473,34	623,9
8	$PM_{10} = - (34,28) + (116,8*NDVI) - (0,031*B1) + (0,093976*B3) - (0,021214*B4)$	0,658	0,636	478,63	491,94
9	$PM_{10} = (145,3) + (116,7 *NDVI) - (0,031*B1) + (0,093*B3) - (0,02*B4) - (0,089*AÑO) + (0,744*SEASON)$	0,662	0,628	481,9	499,66

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Como puede observarse en la Tabla 14 para el sensor “Landsat 8”, el modelo que arroja mejores pronósticos de PM₁₀ es el Modelo 8 pues tiene un valor p de 0.01255 en el siguiente análisis de varianza.

Tabla 14. Análisis de varianza de los modelos generalizados lineales y el modelo lineal multivariante para el sensor "Landsat 8".

Modelos	Res.Df	RSS	Df	Sum of Sq	F	Pr (F)
Modelo lineal multivariante	52	3007,5				
7 Modelo lineal generalizado 1	62	3417,3	-10	-409,85	0,7086	0,7121
8 Modelo lineal generalizado 2	63	3804,1	-1	-386,74	6,6867	0,01255
9 Modelo lineal generalizado 3	61	3763,7	2	40,36	0,3489	0,70711

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

El modelo elegido a partir de los anteriores para el sensor “Landsat 8” se detalla a continuación:

$$PM_{10}_{LANDSAT8} = -34,283 + (116,85 * NDVI) - (0,031902 * B1) + (0,09398 * B3) - (0,0212 * B4) \quad \text{Ec. 28}$$

Donde:

PM₁₀ = Estimación de concentración del material particulado (µg/m³)

B1 = Banda espectral azul con longitud de onda (0,452-0,512) µm

B3 = Banda espectral roja con longitud de onda (0,636-0,673) µm

B4 = Banda espectral infrarroja cercana con longitud de onda (0,851-0,87) μm

5.3.3.1.1. Validación del modelo GLM para el sensor "Landsat 8"

En la gráfica "Residuals vs Fitted" de la Figura 33 se muestra que los residuos no están correlacionados, pues no presentan patrones en su dispersión.

En la gráfica "Normal Q-Q" de la Figura 33 se observa que los residuos estandarizados presentan una tendencia lineal confirmando así su distribución normal.

En la Figura 33 en la gráfica Scale-Location se observa valores que se propagan a medida que la línea se hace curva, sin embargo, la varianza se mantiene constante vinculado con datos de residuos estandarizados y valores ajustados.

La gráfica Residuals vs Leverage permite la visualización de datos atípicos en las variables de la regresión y la posibilidad de eliminación con el objetivo de perfeccionar el modelo (Kim 2015), este se ilustra en la Figura 33.




Figura 33. Gráficas de análisis de los residuos del Modelo 8 para el sensor "Landsat 8".
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

A continuación, se muestran los mapas obtenidos a partir del Modelo 2 por “GLM”.




Figura 34. Clasificación de PM₁₀ estimado para el año 2013.
Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 35. Clasificación de PM₁₀ estimado para el año 2015.
Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 36. Clasificación de PM₁₀ estimado para el año 2017.
Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)

Para el Modelo 10 y 11 se aplicó una transformación logarítmica previa a la variable dependiente PM₁₀.

5.3.3.2. Modelo 10, 11: Regresión Ponderada Geográficamente para el sensor Landsat 8

El Modelo 10 cuya estimación se hace por Regresión Lineal Multivariada se lo plantea con propósitos de comparación; es decir, no se ahondará en la ecuación, pero si en su validación.

El Modelo 11 se estima mediante una Regresión Ponderada Geográficamente que encontraremos utilizando funciones implementadas en la librería SPGWR de R Studio versión 3.4.4.

5.3.3.2.1. Validación cruzada del ancho de banda para el Modelo 10

Fórmula: $gwr.sel (PM_{10} \sim NDWI + BAND_NIR)$ Ec. 29

5.3.3.2.2. Estimación del Modelo de Regresión Ponderada Geográficamente

Fórmula: $gwr (BAND_{BLUE} - BAND_{GREEN} + BAND_{RED} - (BAND_{NIR} * BAND_{SWIR}) - BAND_{NIR} + BAND_{SWIR} - SEASON_2 + SEASON_3 + SEASON_4)$ Ec. 30

5.4. Resumen estadístico de los modelos para el sensor “Landsat 8”

El resumen estadístico de los modelos planteados se presenta en la siguiente tabla:

Tabla 15. Comparación de los modelos generados para el sensor “Landsat 8”

Modelo	Método	R ²	R ² Ajustado	RMSE	AIC
Regresión lineal					
10	Multivariada	0,2701	0,2031	0,3456	99,0085
11	GWR global	0,8347	0,8339	0,1644	-12,7385

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En el Modelo 10 los valores de los coeficientes de determinación fueron R² 0.2701 y R²Ajustado de 0.2031 lo que demuestra una baja bondad de ajuste pues sus valores no son estadísticamente significativos ya que son menores a 0.5, con ello se estableció que este modelo no es bueno para estimar el comportamiento del PM₁₀. Se visualiza en la Figura 33 que los residuos no cumplen con los supuestos de validación.




Figura 37. Gráficas de Residuos vs. Ajustados y Normal Q-Q para “Landsat 8”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Figura 37, la gráfica de Residuos vs. Ajustados muestra forma similar a una parábola y con ello se evidencia que los residuos siguen un patrón determinado por tanto los residuos se encuentran correlacionados y en la gráfica de probabilidad normal de los residuos se observa que no se ajustan a la recta Normal.

En el ajuste del Modelo 11 por Regresión Geográficamente Ponderada para el sensor “Landsat 8” sus valores de coeficientes fueron R^2 de 0.8347, R^2 Ajustado de 0.8339 y además el Criterio de Información de Akaike es inferior al obtenido por Regresión Lineal Multivariante con transformación logarítmica a PM_{10} , siendo el Modelo 11 el que mejor describe al contaminante de estudio.

Los resúmenes estadísticos se muestran en la Tabla 16 y el análisis de varianza en la Tabla 17:

Tabla 16. Resumen de la Regresión Ponderada Geográficamente con datos atípicos para el sensor “Landsat 8”.

	Mínimo	Cuartil 1	Mediana	Cuartil 3	Máximo	Global
Intercepto	-4,0095	-3,9300	1,5170	3,4388	4,2071	3,1011
BAND _{BLUE}	-0,0068	-0,0009	0,0001	0,0006	0,0017	0,0002
BAND _{GREEN}	-0,0026	-0,0018	0,0005	0,0019	0,0030	-0,0006
BAND _{RED}	-0,0029	-0,0002	0,0004	0,0016	0,0070	0,0007
BAND _{NIR}	-0,0021	-0,0002	$1 * 10^{-5}$	0,0025	0,0039	-0,0003
BAND _{SWIR}	-0,0005	-0,0000	0,0010	0,0040	0,0044	0,0004
BAND _{NIR} * BAND _{SWIR}	$-2,06 * 10^{-6}$	$-1,6 * 10^{-6}$	$-3,3 * 10^{-7}$	$7,8 * 10^{-9}$	$3,1 * 10^{-7}$	0,0000

SEASON ₂	-0,6303	-0,2239	-0,1506	0,2685	0,9660	-0,3366
SEASON ₃	-1,3045	-0,0351	0,0669	0,14297	0,9209	0,1745
SEASON ₄	-0,2187	-0,0408	0,0437	0,1777	0,8379	0,0853

Número de datos: 108 observaciones

Sigma: 0,2874393

AIC: -12,73857

R^2 : 0,8347225

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Ecuación:

$$\begin{aligned} \log(PM_{10})_{LANDSAT8} = & 3,1011466 + 0,0002023 BAND_{BLUE} - \\ & 0,0006195 BAND_{GREEN} + 0,0007055 BAND_{RED} - 0,0002805 BAND_{NIR} + \\ & 0,0004290 BAND_{SWIR} - 0,0000001 BAND_{NIR} * BAND_{SWIR} - \\ & 0,0168827 SEASON_2 + 0,1745223 SEASON_3 + 0,0852715 SEASON_4 \quad \text{Ec. 31} \end{aligned}$$

Donde:

PM_{10} = Estimación de concentración del material particulado ($\mu\text{g}/\text{m}^3$)

$BAND_{BLUE}$ = Banda espectral azul con longitud de onda (0,452-0,512) μm

$BAND_{GREEN}$ = Banda espectral verde con longitud de onda (0,533-0,590) μm

$BAND_{RED}$ = Banda espectral roja con longitud de onda (0,636-0,673) μm

$BAND_{NIR}$ = Banda espectral infrarroja cercana con longitud de onda (0,851-0,87) μm

$BAND_{SWIR}$ = Banda espectral infrarroja de onda corta con longitud de onda

$SAVI$ = Índice de vegetación ajustado al suelo

$NDVI$ = Índice de Vegetación de Diferencia Normalizada

$SEASON_2$ = Temporada correspondiente a los meses (abril, mayo y junio)

$SEASON_3$ = Temporada correspondiente a los meses (julio, agosto y septiembre)

$SEASON_4$ = Temporada correspondiente a los meses (octubre, noviembre y diciembre)

Tabla 17. Análisis de varianza de Modelo 11 para el sensor “Landsat 8”.

	Grados de libertad	Suma de cuadrados	Error de cuadrático medio	F- valor
OLS Residuos	10,000	12,9009		
GWR Ajustado	62,643	9,9797	0,159310	
GWR Residuos	35,357	2,9212	0,082621	1,9282

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

A continuación, se muestra en la Figura 38 los valores ajustados del Modelo 11 para el sensor “Landsat 8”.




Figura 38. Dispersión del material particulado (PM₁₀) observado y ajustado mediante el Modelo 11.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.4.1. Validación del Modelo 11




Figura 39. Dispersión de residuos del Modelo 11 para el sensor “Landsat 8”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)
Como se muestra en la Figura 39 los residuos se encuentran dispersos alrededor de cero y no muestran patrones de correlación lo cual evidencia buena calidad en la predicción del modelo.




Figura 40. Ajuste Q-Q normal e histograma de ajuste normal de los residuos con un intervalo de confianza al 99% sensor “Landsat 8”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

De acuerdo al histograma de la Figura 40 se verifica el supuesto de que los residuos estandarizados siguen una distribución normal $N(0,1)$ ya que se ajustan a una Campana de Gauss.

A continuación, se observan los mapas generados a partir del Modelo 11:




Figura 41. Clasificación de PM_{10} estimado para el año 2013.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 42. Clasificación de PM₁₀ estimado para el año 2015.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 43. Clasificación de PM₁₀ estimado para el año 2017.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.5. Sensor “MODIS”

5.5.1. Análisis de información recopilada de PM₁₀

En la Figura 44, se muestra el diagrama de cajas considerando los cuantiles: 0.25, 0.50 y 0.75; para los valores promedios diarios, recolectados en las estaciones de la REMMAQ, teniendo en cuenta datos recopilados en los meses de enero a diciembre, en los años desde el 2003 al 2017, donde LMP1 = 50µg/m³ este valor es el PM₁₀ límite máximo promedio para la Organización Mundial de la Salud (Organización Mundial de la Salud, 2018) y LMP2 = 100 µg/m³ es el PM₁₀ límite máximo promedio vigente en la Norma Ecuatoriana de la Calidad del Aire (Ministerio del Ambiente, 2011).




Figura 44. Diagrama de cajas del PM₁₀ por estación en la REMMAQ.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Figura 44, se observa que en la mayoría de estaciones los valores promedios diarios de PM₁₀ exceden el LMP1 y la estación Carapungo excede el LMP2; además, hay presencia de puntos atípicos en todas las estaciones ubicadas a lo largo del Distrito

Metropolitano de Quito. Para la estación San Antonio no hay información de PM₁₀ durante el periodo en estudio.

5.5.2. Descripción de la data

Tabla 18. Descripción de los datos para el sensor “MODIS”

Variables	Mínimo	Máximo	Media	Desviación estándar
PM ₁₀	7,39	360,7	52,21	44,16
NDVI	-0,13	0,71	0,27	0,14
NDWI	-1,05	1,81	0,45	0,47
LST	0	39,51	29,83	6,74
NSI	-0,01	0,14	0,05	0,02
SAVI	-0,2	1,06	0,41	0,2
BANDA 1	33	3334	931,55	398,95
BANDA 2	211	3662	1202,94	400,16
BANDA 3	326	3737	1343,9	418,62
BANDA 4	871	4032,5	2294,77	411,22
BANDA 5	1145	4291,5	2530,51	417,87

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Tabla 18 para el sensor “MODIS” se observa que la desviación estándar de la variable PM₁₀ es alta comparada con las variables independientes BANDA 1, BANDA 2, BANDA 3, BANDA 4, BANDA 5. La existencia de variabilidad en PM₁₀ se mitigó aplicando una transformación logarítmica a los datos con la finalidad de reducir la varianza, conservar las propiedades y tendencia.

La Figura 45 y Figura 46 muestra un gráfico de dispersión de la variable dependiente PM_{10} con respecto a las variables independientes (NDVI, NSI, SAVI, LST, BANDA 1, BANDA 2, BANDA 3, BANDA 4, BANDA 5), con el fin de mostrar la relación existente entre las variables:




Figura 45. Gráficas de dispersión de la variable PM_{10} vs. NDVI, NDWI, LST, NSI, SAVI (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “MODIS”.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 46. Gráficas de dispersión de la variable PM_{10} vs. B1, B2, B3, B4, B5 (ajuste de regresión polinomial local) con un intervalo de confianza del 95% sensor “MODIS”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Tabla 19 se muestra la correlación entre la variable dependiente (PM_{10}) con las variables independientes (NDVI, NSI, SAVI, LST, BANDA 1, BANDA 2, BANDA 3, BANDA 4, BANDA 5) y la correlación existente entre la variable transformada log (PM_{10}) con las variables independientes (NDVI, NSI, SAVI, LST, BANDA 1, BANDA 2, BANDA 3, BANDA 4, BANDA 5).

Tabla 19. Correlación entre variables dependientes y variables independientes para el sensor “MODIS”.

Variables	Correlación de Pearson	Variables	Correlación de Pearson
PM_{10} con NDVI	-0,1497	log (PM_{10}) con NDVI	-0,1721
PM_{10} con NDWI	0,1775	log (PM_{10}) con NDWI	0,1613
PM_{10} con LST	0,0926	log (PM_{10}) con LST	0,0456
PM_{10} con NSI	0,1559	log (PM_{10}) con NSI	0,1398
PM_{10} con SAVI	-0,1497	log (PM_{10}) con SAVI	-0,1736
PM_{10} con BANDA 1	0,1059	log (PM_{10}) con BANDA 1	0,1308
PM_{10} con BANDA 2	0,1299	log (PM_{10}) con BANDA 2	0,1404
PM_{10} con BANDA 3	0,1294	log (PM_{10}) con BANDA 3	0,136
PM_{10} con BANDA 4	-0,0017	log (PM_{10}) con BANDA 4	-0,036
PM_{10} con BANDA 5	0,001	log(PM_{10}) con BANDA 5	0,041

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Se puede observar que la correlación entre las variables independientes (NDVI, NSI, SAVI, LST) con PM_{10} es cercana a cero; la correlación entre la variable dependiente transformada log (PM_{10}) y las variables BANDA 1, BANDA 2, BANDA 3, BANDA 4,

BANDA 5 si bien muestran valores de correlación bajos estas variables son independientes a diferencia de LST, NDVI, NDWI, SAVI las cuales dependen de las bandas. En la Figura 52 se evidencia la relación lineal existente.




Figura 47. Gráficas de dispersión, ajuste lineal y ancho de banda al 95% entre log (PM₁₀) vs. (BAND B1, B2, B3, B4, B5) y log (PM₁₀) vs. (NDVI*SAVI) sensor “MODIS”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.5.3. Análisis de los modelos generados

En la fase preliminar se consideraron cinco modelos:

- Modelo 12, 13, 14: Regresión lineal generalizada.
- Modelo 15: Regresión lineal considerando una transformación logarítmica a PM_{10} .
- Modelo 16: Regresión ponderada geográficamente considerando una transformación logarítmica a PM_{10} .

5.5.3.1. Modelo 12, 13, 14: Regresión lineal generalizada sin transformación logarítmica para el sensor “MODIS”

Para la estimación de los modelos se ajustaron 205 observaciones a partir de imágenes satelitales provistas por el sensor de estudio en periodos cuatrimestrales durante los años 2003-2017.

La Tabla 20 muestra los coeficientes de determinación de los Modelos 12, 13 y 14 para el sensor “MODIS”, los cuales son estadísticamente significativos pues tienen valores de R^2 mayores a 0.5.

Tabla 20. Análisis estadístico de los modelos resultantes para el sensor “MODIS”

Modelo	Ecuaciones	R ²	R ² Aj.	AIC	BIC
12	$PM_{10} = (4627,64) + (77,65*LONG) - (18,10*NDVI) + (9,61*NDWI) - (1,20*LST) + (0,76*AÑO)$	0,58	0,564	564,35	584,34
13	$PM_{10} = (4066) + (75,33*LONG) + (1,23*NDVI) + (8,46*NDWI) - (1,14*LST) - (0,0011*B1) + (1,457*B2) - (0,00095*B3) + (93,24*AÑO)$	0,636	0,6	557,21	582,20
14	$PM_{10} = (2827,46) + (56,20*LONG) + (10,14*NDWI) - (1,10*LST) + (0,818*AÑO)$	0,534	0,512	571,48	586,47

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Tabla 21 para el Test de Fisher se obtienen valores de p menores a 0.05, en particular el Modelo 14 tiene el menor valor p=0.00032; por tanto, se escoge a partir de éstos como el modelo con mejor capacidad predictiva.

Tabla 21. Análisis de varianza de los modelos para el sensor "MODIS"

Modelos	Res.Df	RSS	Df	Sum of Sq	F	Pr (F)
Modelo lineal multivariante	75	1824,1				
12 Modelo lineal generalizado 1	83	2332,5	-8	-508,41	2,6130	0,014

13	Modelo lineal generalizado 2	81	2060,9	2	271,62	5,5841	0,00548
14	Modelo lineal generalizado 3	85	2639	-4	-578,70	5,9484	0,00032

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

La ecuación del Modelo 14 para el sensor “MODIS” se detalla a continuación:

$$PM_{10}^{MODIS} = 2827,5 + (56,21 * LONG) + (10,15 * NDWI) - (1,10 * LST) + (0,82 * AÑO) \quad \text{Ec. 32}$$

Donde:

PM_{10} = Estimación de la concentración del material particulado ($\mu g/m^3$)

Longitud = Coordenada geográfica de la imagen satelital

LST = Temperatura de superficie

$NDWI$ = Índice diferencial de agua normalizado

$AÑO$ = Año de la imagen satelital

5.5.3.1.1. Validación del modelo GLM

En la Figura 48 “Residuals vs Fitted” se observa correlación entre los residuos y las observaciones ajustadas y además puntos atípicos que pueden ser producto de errores en la medición del contaminante criterio.

En la Figura 48 “Normal Q-Q” evidencia residuos estandarizados localizados fuera de la línea Normal, entonces no todos siguen una distribución normal.

En la gráfica Scale-Location los valores se propagan a medida que la línea se hace curva; sin embargo, la varianza se mantiene constante entre los residuos estandarizados y los valores ajustados y en la gráfica Residuals vs Leverage presenta anomalías en los

puntos 34, 2 no son estadísticamente explicativos, pero podrían mantenerse dentro de los datos pues su distancia de Cook es baja.




Figura 48. Gráficas de análisis de residuos del Modelo 14 para el sensor "MODIS".
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En los siguientes mapas se muestra el Modelo 14 para estimar el PM₁₀:




Figura 49. Clasificación de PM₁₀ estimado para el año 2013.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 50. Clasificación de PM₁₀ estimado para el año 2015.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)




Figura 51. Clasificación de PM₁₀ estimado para el año 2017.
 Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.3.3.2. Modelo 15 y 16: Regresión Ponderada Geográficamente

En el Modelo 15 y 16 se empleó una transformación logarítmica a la variable dependiente PM_{10} . El Modelo 15 cuya estimación se hace por Regresión Lineal Multivariada se lo plantea con propósitos de comparación; es decir, no se profundizará en la ecuación, pero si en su validación.

El Modelo 16 se estima mediante una Regresión Ponderada Geográficamente que encontraremos utilizando funciones implementadas en la librería SPGWR de R Studio.

5.5.3.2.1. Validación cruzada del ancho de banda para el Modelo 16

Fórmula: $\text{gwr.sel}(\text{PM10} \sim \text{BANDA 1} + \text{SAVI})$ Ec. 33

5.5.3.2.2. Estimación del Modelo de Regresión Ponderada Geográficamente

Fórmula: $\text{gwr}(\text{BANDA 1} + \text{BANDA 2} - \text{BANDA 3} + (\text{BANDA 4} * \text{BANDA 5}) - \text{BANDA 4} + \text{BANDA 5} + \text{NDVI} - \text{SAVI} - (\text{NDVI} * \text{SAVI}) - \text{SEASON}_2 + \text{SEASON}_3 + \text{SEASON}_4)$ Ec. 34

5.6. Resumen estadístico de los modelos ponderados geográficamente para el sensor “MODIS”

A continuación, se muestran los resúmenes estadísticos del Modelo 15 y 16

Tabla 22. Comparación de los modelos generados para el sensor “MODIS”.

Modelo	Método	R ²	R ² Ajustado	RMSE	AIC
Regresión					
15	Lineal	0,0865	0,0294	0,5938	396,1351
	Multivariada				
16	GWR	0,6161	0,6152	0,3849	289,5802

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Para el Modelo 15 los coeficientes de determinación R² y R² ajustado no son estadísticamente significativos ya que sus valores son menores a 0.5 evidenciando así la baja bondad de ajuste de este modelo. Además, los residuos del Modelo 15 no cumplen con los supuestos de validación como puede verificarse en la siguiente Figura:




Figura 52. Gráficas de Residuos vs. Ajustados y Normal Q-Q del Modelo 15 para el sensor “MODIS”.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

La Figura 52 de Residuos vs. Ajustados evidencia que los residuos están correlacionados y la gráfica Normal Q-Q muestra que los residuos estandarizados no se ajustan a la recta Normal.

El Modelo 16 ajustado mediante Regresión Geográficamente Ponderada para el sensor “MODIS” tiene coeficientes de determinación R^2 de 0.6161 y R^2 Ajustado de 0.6152 los cuales son estadísticamente significativos pues son mayores a 0.5; concluyendo que el Modelo 16 ajusta bien el contaminante criterio.

La Tabla 23 y 24 muestran el resumen estadístico y el análisis de varianza respectivamente para el Modelo 16.

Tabla 23. Resumen de la Regresión Ponderada Geográficamente para el sensor “MODIS”.

	Mínimo	Cuartil 1	Mediana	Cuartil 3	Máximo	Global
Intercepto	-2,6751	0,7748	4,437	8,5267	10,023	4,2666
BANDA 1	-0,0018	-0,0009	0,0007	0,0010	0,0012	0,0002
BANDA 2	-0,0015	0,0005	0,0013	0,0026	0,0027	0,0008
BANDA 3	-0,0064	-0,0026	-0,0013	$3,6 * 10^{-5}$	0,0050	-0,0013
BANDA 4	-0,0056	-0,0021	-0,0009	$-2,5 * 10^{-5}$	0,0025	-0,0006
BANDA 5	-0,0018	-0,0013	0,0003	0,0022	0,0033	0,0006
BANDA 4 * BANDA 5	$-7,2 * 10^{-7}$	$-2,5 * 10^{-7}$	$-3 * 10^{-8}$	$8,2 * 10^{-7}$	$9,2 * 10^{-7}$	$4 * 10^{-8}$

NDVI	-20,790	-6,9496	22,261	37,304	62,386	9,8937
SAVI	-51,384	-17,831	-11,829	3,7529	22,205	-7,5710
NDVI * SAVI	-47,753	-9,7236	-0,7382	6,6152	17,075	-0,2484
SEASON ₂	-0,3869	-0,1509	-0,0079	0,0879	0,4746	-0,0934
SEASON ₃	-0,6437	0,0157	0,0558	0,5496	1,0411	0,1825
SEASON ₄	-0,2328	-0,0843	0,2161	0,3440	0,8806	0,1731

Número de datos: 205 observaciones

Sigma: 0,5473809

AIC: 289, 5802

R^2 : 0,6161414

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Ecuación:

$$\begin{aligned} \log(PM_{10})_{MODIS} = & 4,26655918 + 0,00024465 \text{ BANDA } 1 + \\ & 0,00082859 \text{ BANDA } 2 - 0,00132685 \text{ BANDA } 3 - 0,00057177 \text{ BANDA } 4 + \\ & 0,00057534 \text{ BANDA } 5 + 0,00000004 \text{ BANDA } 4 * \text{ BANDA } 5 + 9,89367217 \text{ NDVI} - \\ & 7,57099244 \text{ SAVI} - 0,24842812 (\text{NDVI} * \text{SAVI}) - 0,09340426 \text{ SEASON}_2 + \\ & 0,18247206 \text{ SEASON}_3 + 0,17314576 \text{ SEASON}_4 \quad \text{Ec. 35} \end{aligned}$$

Donde:

PM_{10} = Material particulado ($\mu g/m^3$)

$BANDA$ 1 = Banda espectral azul con longitud de onda (0,452-0,512) μm

$BANDA$ 2 = Banda espectral verde con longitud de onda (0,533-0,590) μm

$BANDA$ 3 = Banda espectral roja con longitud de onda (0,636-0,673) μm

$BANDA$ 4 = Banda espectral infrarroja cercana con longitud de onda (0,851-0,87) μm

$BANDA$ 5 = Banda espectral infrarroja de onda corta con longitud de onda

$SAVI$ = Índice de vegetación ajustado al suelo

$NDVI$ = Índice de Vegetación de Diferencia Normalizada

$SEASON_2$ = Temporada correspondiente a los meses (abril, mayo y junio)

$SEASON_3$ = Temporada correspondiente a los meses (julio, agosto y septiembre)

$SEASON_4$ = Temporada correspondiente a los meses (octubre, noviembre y diciembre)

Tabla 24. Análisis de varianza del Modelo 16 para el sensor “MODIS”.

	Grados de libertad	Suma de cuadrados	Error cuadrático medio	F- valor
OLS Residuos	13,000	72,306		
GWR Ajustado	90,588	41,921	0,46276	
GWR Residuos	101,412	30,386	0,29963	1,5445

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

A continuación, se muestra en la Figura 53 los valores de PM₁₀ Ajustados a partir del Modelo 16 para el sensor “MODIS”.




Figura 53. Gráfico de dispersión del material particulado (PM₁₀) observado y ajustado mediante el Modelo 16.

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

5.6.3. Validación del Modelo 16



Figura 54. Gráfico de dispersión de residuos del Modelo 16 para el sensor “MODIS”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

En la Figura 54 se observa que los residuos se encuentran dispersos alrededor del cero y no presentan patrones, evidenciando la ausencia de correlación y con ello la calidad de predicción del modelo obtenido.




Figura 55. Ajuste Q-Q normal e histograma de ajuste normal de los residuos con un intervalo de confianza al 99% sensor “MODIS”.
Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

De acuerdo al histograma de la Figura 55 se verifica el supuesto de que los residuos estandarizados siguen una distribución normal $N(0,1)$ ya que se ajustan a una Campana de Gauss.

A continuación, se muestran los mapas generados a partir del Modelo 16:




Figura 56. Clasificación de PM_{10} estimado mediante el Modelo 16 para el año 2013. Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 57. Clasificación de PM₁₀ estimado mediante el Modelo 16 para el año 2015.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)




Figura 58. Clasificación de PM₁₀ estimado mediante el Modelo 16 para el año 2017.
 Elaborado por: Torres N., Vivanco V., 2018 (ArcGIS 10.5)

5.7. Comparación de todos los modelos generados para estimar el PM₁₀ en la REMMAQ por sensor

En la Tabla 25 se muestra el resumen estadístico de los modelos generados para el presente estudio, donde:

GLM representa una Regresión Lineal Generalizada, LM Regresión Lineal Simple y GWR una Regresión Ponderada Geográficamente.

Tabla 25. Resumen estadístico de los modelos generados

Modelo aplicado	Sensor Satelital	Número de observaciones	R ²	R ² Aj.	AIC
GLM	Landsat 7*	228	0,7075	0,6903	603,2
GLM	Landsat 8	218	0,6585	0,6368	478,63
GLM	MODIS	439	0,5347	0,5128	571,48
LM	Landsat 7	228	0,1261	0,0702	277,83
LM	Landsat 8	218	0,2701	0,2031	99,00

LM	MODIS	439	0,0865	0,0294	396,13
GWR	Landsat 7	228	0,6730	0,6721	195,62
GWR	Landsat 8*	218	0,8347	0,8339	-12,73
GWR	MODIS*	439	0,6161	0,6152	289,58

Elaborado por: Torres N., Vivanco V., 2018 (R Studio 3.4.4)

Nota: El signo * muestra el modelo que mejor estima al PM_{10} por sensor de estudio.

5.8. DISCUSIÓN

Para evidenciar el deterioro de la calidad del aire se aplicó la teledetección a partir de las imágenes satelitales generadas en tres sensores remotos y en la que se consideró la máxima concentración de PM_{10} con diámetro menor a $10\ \mu m$ usando datos horarios históricos emitidos por la Red de Monitoreo Atmosférico entre 2003 y 2017. Se creó una matriz multivariable con indicadores ambientales generados a partir de las bandas multispectrales (NDVI, NDWI, NSI, SAVI, LST) que permitieron generar modelos para estimar el material particulado en los sitios de estudio. Los sensores del estudio fueron: “MODIS” formado por los satélites TERRA y AQUA (1999, 2002) (Pons, 2003), “Landsat 7” (1999) (Instituto Nacional de Estadística y Geografía (INEGI), 2014) y “Landsat 8” (2013) (Geoservice Peru, 2015).

El análisis exploratorio, ajuste y validación de los modelos se realizó para 15 indicadores con 228 observaciones a partir de promedios cuatrimestrales en el caso del sensor “Landsat 7”, 218 observaciones para el sensor “Landsat 8” y 438 para el sensor “MODIS”.

Se evidenció la presencia de valores atípicos de PM_{10} en la estación de Carapungo: $204.5\ \mu g/m^3$ en los meses de enero a marzo (2007), $256\ \mu g/m^3$ abril a junio (2006), $360.7\ \mu g/m^3$ julio a septiembre (2009) y $185.9\ \mu g/m^3$ octubre a diciembre (2008) valores que superan el límite máximo permisible de la (Organización Mundial de la Salud, 2018) que es de $50\ \mu g/m^3$. Esto puede deberse a que al ser una zona industrial para el año 2009 coexistían las actividades económicas tales como: 49 locales de metalmecánica, 31 de madera, 20 de plásticos, 6 de marmolería entre otras (Administración Zonal Calderón, 2009), además de 2 canteras que se dedicaban a la extracción de materiales de

construcción con una superficie de 184 ha (Dirección Regional de Minería de Pichincha (DIREMIP), 2009), esta estación supera la Normativa Nacional), otra razón del aumento de este contaminante en esta zona puede provocarse por la presencia de vías no asfaltadas, erosión eólica del suelo entre otros factores. Estudios recientes como (Abad, 2016) concluyeron que en el año 2011 en la Ciudad de Cuenca se superó la normativa de $50 \mu\text{g}/\text{m}^3$ para material particulado.

En el Ecuador el uso de imágenes satelitales en la determinación del deterioro de la calidad del aire es reciente. El estudio realizado por (Alvarez Mendoza, 2014a) en la ciudad de Quito arrojó modelos de estimación de material particulado durante los años 2005, 2008 y 2011 mediante imágenes provistas por el sensor “Landsat 7 +ETM” basándose en una regresión lineal múltiple y considerando un total de 8 indicadores como: NDVI, NSI, LWCI, SAVI, TB, B1, B2, B3; resultando valores de $R^2 = 0.99$, aquí es importante indicar que los resultados alcanzados pudieron evidenciar valores óptimos al trabajar con menor número de imágenes procesadas, explicando de mejor manera el PM_{10} , a diferencia de los resultados arrojados en este estudio, donde se trabajó con un total de 3 sensores “Landsat 7”, “Landsat 8” y MODIS considerando 15 indicadores como: NDVI, NSI, NDWI, SAVI, LST, B1, B2, B3, B4, B5, AÑO, SEASON 1, SEASON 2, SEASON 3, SEASON 4 resultando valores de R^2 y R^2 ajustado de $0.70 - 0.69$; $0.65 - 0.63$; $0.53 - 0.51$ respectivamente.

Los modelos planteados fueron: regresión lineal generalizada (Modelo 3) y la regresión ponderada geográficamente (Modelo 5).

Para el sensor “Landsat 7” se eligió el Modelo 3 generado a partir de una regresión lineal generalizada, ya que sus coeficientes de determinación fueron $R^2 = 0.70$ y R^2 ajustado = 0.69 con lo que fue posible estimar el PM_{10} . En un principio se consideró

trabajar los datos en bruto sin eliminación de valores atípicos obteniéndose valores de R^2 y R^2 ajustado de 0.30, 0.27 respectivamente y con ello corroborando que la eliminación de datos atípicos contribuye a la mejora de criterios estadísticos. Además las imágenes generadas por este sensor presentaban problemas de bandeo radiométrico generado por una falla existente en el instrumento corrector de líneas escaneadas Scan Line Corrector (SLC-off) mismo que se halla apagado desde el mes de mayo de 2003 producto de esto las escenas que se pudieron adquirir contienen franjas de datos inválidos provocando una pérdida del 22% de la información colectada (Cristóbal, Pons, Serra, & Es, 2003; Jiménez, 2010).

Tanto para el sensor “Landsat 8” y “MODIS”, el modelo estimado a partir de una regresión ponderada geográficamente presenta mejor calidad de resultados al aplicar el criterio de correlación de Pearson para la elección de la banda óptima. Es importante destacar que fue necesario aplicar una transformación logarítmica a la variable PM_{10} ya que los datos no tenían un comportamiento uniforme y con ello se garantizó que las predicciones no sean negativas y además brinden estabilidad a la media.

Luego de aplicar la regresión geográficamente ponderada se encontró R^2 ajustado= 0.83 y 0.6 para los Modelos 16 y 11 para los sensores “Landsat 8” y “MODIS” respectivamente, estos valores se encuentran dentro de rangos reportados según (Valiente & Herranz, 2010) menciona que si el coeficiente de determinación es cercano a uno tiende a ajustarse de manera óptima a la regresión.

En la actualidad no existen estudios de calidad aire a nivel nacional aplicando la regresión ponderada geográficamente, por lo que no es posible realizar una comparación de resultados.

Sin embargo a nivel mundial existen investigaciones a través de este método señalando valores de R^2 Ajustado entre 0.6 y 0.8 (Song, Jia, Huang, & Zhang, 2014; Zhang et al., 2016) y un estudio en el área de la salud en Seúl por (Romieu et al., 2012) indicó un valor de R^2 Ajustado de 0.208, con lo cual se puede concluir que la calidad de los Modelos 11 y 16 se encuentran dentro de un rango aceptable.

Gracias al análisis de los resultados se podría afirmar que los Modelos 16 y 11 generados a partir de regresión ponderada geográficamente, tienen el mejor desempeño para estimar la concentración de PM_{10} para los sensores “Landsat 8” y “MODIS” en el Distrito Metropolitano de Quito ya que se consideran las coordenadas geográficas de las estaciones en la ciudad para ponderar el contaminante de estudio calculando las distancias mínimas entre observaciones (kernel), aunque presenta dificultades debidas a que no en todas las estaciones se encontraba el valor del contaminante criterio y por ello limitando la investigación.

Por otro lado, se debe mencionar que durante la adquisición de imágenes se analizó el porcentaje de nubosidad en cada escena satelital para una buena extracción de datos, disminuyendo el número de observaciones iniciales.

Para mejorar los resultados de los modelos propuestos se debería incluir variables meteorológicas además realizar un tratamiento previo mediante el enmascaramiento de nubes con el objetivo de visualizar de mejor manera el área en estudio.

6. CONCLUSIONES Y RECOMENDACIONES

6.1. Conclusiones

Se determinó la influencia de material particulado considerando las estaciones de monitoreo de la Red Metropolitana de Monitoreo Atmosférico de Quito, detectándose en la zona de Carapungo para el año 2009 durante los meses de julio a septiembre $360.7 \mu\text{g}/\text{m}^3$ excediendo este valor, tanto a la Normativa Nacional vigente ($100 \mu\text{g}/\text{m}^3$) (Ministerio del Ambiente, 2011), así como de la (Organización Mundial de la Salud, 2018) ($50 \mu\text{g}/\text{m}^3$), posiblemente este valor puede deberse al predominio de actividades como: el transporte público, la industria de la construcción y actividades asociadas a fuentes industriales.

A partir de los datos de PM_{10} históricos comprendido entre los años 2003 al 2017, proporcionados por la Secretaría del Ambiente, se analizó el comportamiento de este contaminante en las estaciones de monitoreo de la Red Metropolitana de Monitoreo Atmosférico de Quito con respecto al clima de la ciudad, observándose que durante los meses de octubre a mayo el material particulado disminuía, caso contrario en los meses de junio a septiembre la concentración de éste aumentaba, esto puede estar relacionado con la temporada seca y lluviosa.

Las imágenes satelitales provenientes de los tres sensores en estudio fueron procesadas previamente, para ello fue necesario transformar los valores de radiancia a números digitales de cada pixel antes de la generación de los modelos, evitando así, problemas de bandeo y valores negativos al calcular la temperatura de superficie a nivel de suelo. Posterior a ello se extrajeron los valores de cada banda espectral para cada sensor y así realizar el cálculo de indicadores tales como NSI, SAVI, NDWI, LST, NDVI en cada

estación. Esta metodología puede ser aplicada en ciudades que cuenten con una Red de Monitoreo Atmosférico un ejemplo tangible es en la ciudad de Cuenca.

El modelo que mejor describe el comportamiento de la variable PM_{10} en la ciudad de Quito fue el Modelo 16 obtenido mediante una Regresión Ponderada Geográficamente a partir de las imágenes satelitales provistas por el sensor “Landsat 8” resultando valores de R^2 Y R^2 ajustado de 0.83 y 0.61 respectivamente. Este modelo tiene ventajas frente a los demás debido a que hace una estimación del contaminante en función de la ubicación geográfica; sin embargo, la principal limitante fue la ausencia de datos en ciertas estaciones de monitoreo de la REMMAQ. Esta metodología puede ser empleada por la Secretaria del Ambiente a futuro ya que no genera costos debido a que la plataforma que provee el Servicio Geológico de los Estados Unidos es gratuita y de fácil acceso, a diferencia del método de monitoreo empleado actualmente para la determinación de PM_{10} que utiliza equipos de medición que requieren calibración e inversión de capital.

6.2.Recomendaciones

Se recomienda el desarrollo de una extensa investigación de PM_{10} debido a que el único proyecto piloto se remonta al año 2007, adicional a ello se debería incluir en la formulación del modelo de estimación de otros contaminantes que guarden una estrecha relación con el material particulado entre ellos: NO_x , SO_2 , COV. Además de la inclusión de variables meteorológicas tales como: temperatura, velocidad y dirección del viento debido a que estas últimas influyen tanto en el transporte y dispersión del contaminante.

Para un mejor rendimiento de la estimación del modelo se necesita una mejor calidad de los datos en cuanto a la exactitud, completitud, integridad, actualización, coherencia y confiabilidad necesarias para el análisis respectivo.

Contar con un mapa por uso de suelo con el objetivo de encontrar sectores aledaños a fuentes de área ya que estas contribuyen en mayor porcentaje a la formación de PM_{10} y donde se evidencie los lugares cercanos a canteras para la determinación de áreas de influencia y la generación de modelos específicos en estos sectores. Además de la creación de políticas que vayan en beneficio de la población expuesta debido a que se encontró prevalencia de enfermedades tales como: tuberculosis, silicotuberculosis, fibrosis y silicosis.

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. Retrieved from <http://dspace.ucuenca.edu.ec/bitstream/123456789/25484/1/TESIS.pdf>
- Administración Nacional de la Aeronáutica. (2015a). MOD 09 - Surface Reflectance; Atmospheric Correction Algorithm Products. Retrieved from https://modis.gsfc.nasa.gov/data/dataproducts.php?MOD_NUMBER=09
- Administración Nacional de la Aeronáutica. (2015b). MOD 13 - Gridded Vegetation Indices (NDVI & EVI). Retrieved July 16, 2018, from https://modis.gsfc.nasa.gov/data/dataproducts.php?MOD_NUMBER=13
- Administración Nacional de la Aeronáutica. (2015c). MODIS AEROSOL PRODUCT. Retrieved July 16, 2018, from <https://modis.gsfc.nasa.gov/data/dataproduct/mod04.php>
- Administración Nacional de la Aeronáutica. (2015d). MODIS Land Surface Temperature and Emissivity (MOD11). Retrieved from <https://modis.gsfc.nasa.gov/data/dataproduct/mod11.php>
- Administración Zonal Calderon. (2009). *Primer Gabinete*. Quito.
- Aguilar Arias, H., Mora Zamora, R., & Vargas Bolaños, C. (2015). Metodología Para La Corrección Atmosférica De Imágenes Aster, Rapideye, Spot 2 Y Landsat 8 Con El Módulo Flaash Del Software Envi. Atmospheric Correction Methodology for Aster, Rapideye, Spot 2 and Landsat 8 Images With Envi Flaash Module Software. *Revista Geográfica de América Central*, 2(53), 39–59. <https://doi.org/10.15359/rgac.2-53.2>
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions Automat Control*, 6(19), 716–723.

- Akaike, H. (1981). Likelihood of a model and information criteria. *Econometrica*, 1(16), 3–14.
- Akaike, H. (1983). Information measures and model selection. *Int. Stat. Inst.*, 1(50), 277–290.
- Alvarez Mendoza, C. I. (2014a). Estimación De Contaminación Del Aire Por Pm10 En Quito Determinado Por Indices Ambientales Obtenidos Con Imágenes Satelitales Landsat Etm+. *Vicerrectorado de Investigación y Vinculación Con La Colectivida*, 53, 104.
- Alvarez Mendoza, C. I. (2014b). Estimación De Contaminación Del Aire Por Pm10 En Quito Determinado Por Indices Ambientales Obtenidos Con Imágenes Satelitales Landsat Etm+. *Vicerrectorado de Investigación y Vinculación Con La Colectivida*, 53, 104. Retrieved from <http://repositorio.espe.edu.ec/bitstream/21000/8675/1/T-ESPE-047962.pdf>
- Arango, M., Branch, J., & Botero, V. (2005). Clasificación no supervisada de coberturas vegetales sobre imágenes digitales de sensores remotos “Landsat-ETM+.” *Facultad Nacional de Agronomía*, 58(1), 2612–2634.
- Ariza Alexander. (2013). Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission). *Centro de Investigación y Desarrollo En Información Geográfica Del IGAC -CIAF*, 46. <https://doi.org/10.5751/ES-06710-190329>
- Arozarena, A., Otero, I., & Ezquerro, A. (2016). *Sistemas de Captura de la Información Fotogrametría y Teledetección*. España, Madrid: Dextra Editorial S.L.
- Artiñano, B., Salvador, P., Alonso, D., Querol, X., & Alastuey, A. (2003). Anthropogenic and natural influence on the PM(10) and PM(2.5) aerosol in Madrid (Spain). Analysis

of high concentration episodes. - PubMed - NCBI. *Environ Pollut*, 3(125), 453–465.

Retrieved from <https://www.ncbi.nlm.nih.gov/pubmed/12826423>

Bo-cai, G. (1996). NDWI-Un índice de diferencia de agua normalizada para la detección remota de agua líquida de vegetación desde el espacio Teledetección del entorno. *Teledetección Del Entorno*, 58(3), 257–266. [https://doi.org/https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/https://doi.org/10.1016/S0034-4257(96)00067-3).

Brunsdon, C., Fotheringham, A., & Charlton, M. (1996). Geographically weighted regression: a meto for exploring spatial nonstationary. *Geographical Analysis*, 4(28), 281–298.

Campbell, J. (1981). Spatial correlation effects upon accuracy of supervised clasification of land cover. *Photogrammetric Engineering and Remote Sensing*, 47, 355–363.

Centro Internacional de Agricultura Tropical (CIAT). (2007). Mejora De Los Sistemas De Cartografía Del Territorio Colombiano. *Mejora de Los Sistemas de Cartografía Del Territorio Colombiano*, 43. Retrieved from ftp://ftp.ciat.cgiar.org/DAPA/planificacion/GEOMATICA/Teledeteccion/Teledeteccion_Modulo.pdf

Chavez, J. (1996). Image based atmospheric corrections-Revisited and improved. *Photogrammetric Engineering and Remote Sensing*, 62, 1025–1036. Retrieved from <https://pdfs.semanticscholar.org/45f1/2625ce130261c7d360d50e09c635355ca919.pdf>

Chuvienco, E. (1995). *Fundamentos de Teledeteccion Espacial* (segunda ed). Madrid España: Ediciones Rialp S.A. Madrid.

Chuvienco, E. (2000). *Fundamentos de Teledeteccion espacial* (Tercera Ed). Madrid España: Ediciones Rialp S.A. Madrid.

- Chuvieco, E., & Hantson, S. (2010). Procesamiento estándar de imágenes Landsat, 1–21.
- Clay, F. (2015). Understanding Q-Q Plots. Retrieved May 26, 2018, from <http://data.library.virginia.edu/understanding-q-q-plots/>
- Cliff, A., & Ord, J. (1973). *Spatial Autocorrelation*. Pion, London.
- Cortes, D. (2000). *Diccionario de ciencias de la tierra*. (Universidad Press Oxford, Ed.) (Primera Ed). Madrid, España: Editorial Complutense.
- CRAN Rstudio. (2016). *Analysis of Deviance for Generalized Linear Model Fits*. Retrieved from <https://stat.ethz.ch/R-manual/R-devel/library/stats/html/anova.glm.html>
- Cristóbal, J., Pons, X., Serra, P., & Es,) Xavier Pons@uab. (2003). Sobre el uso operativo de Landsat-7 ETM+ en Europa. *Teledeteccion y Desarrollo Regional*, 193–196. Retrieved from <http://www.aet.org.es/congresos/x/cac45.pdf>
- Damodar, N., Gujarati, D., & Porter, C. (2010). *Econometria* (Quinta Edi). Mexico: MCGRAW-HILL/INTERAMERICANA EDITORES, S.A. DE C.V.
- Dash, P., Göttsche, F., Olesen, F., & Fischer, H. (2002). Land surface temperature and emissivity estimation from passive sensor data: theory and practice-current. *International Journal of Remote Sensing*, 23, 2563–2594.
- De la Fuente, S. (2011). *Regresión Lineal Múltiple* Santiago de la Fuente Fernández.
- Didan, K., University of Arizona, A. H., Sydney, U. of T., & NASA, M. S.-. (2015). MOD13Q1 - MODIS/Terra Vegetation Indices 16-Day L3 Global 250m SIN Grid. <https://doi.org/10.5067/MODIS/MOD13Q1.006>
- Dirección Metropolitana de Medio Ambiente. (2011). *Perspectivas del ambiente y cambio climático en el medio urbano*: (Fondo Ambiental del Municipio del Distrito Metropolitano de Quito, Ed.). Ecuador. Retrieved from

<http://www.flacsoandes.edu.ec/libros/digital/54250.pdf>

Dirección Regional de Minería de Pichincha (DIREMIP). (2009). “*Memorando 1156 DIREMIP 2009: Información de las concesiones mineras pertenecientes al Distrito Metropolitano de Quito.*” Quito.

Garcia-Mora, T. J., & Mas, J. F. (2011). Evaluacion de imagenes del sensor MODIS para la cartografia de la cobertura del suelo en una region altamente diversa de mexico. *Boletin de La Sociedad Geologica Mexicana*, 63(1), 83–94.

Garcia, S. (2016). *Generalizacion de variables medioambientales mediante interpolacion GIS*. España , Madrid: UNIVERSIDAD POLITECNICA DE MADRID.

Geoservice Peru. (2015). *INFORMACION TECNICA RESUMIDA-LANDSAT 7 ETM*. Retrieved from www.gsp-peru.com

Gollini, I., Charlton, M., Brunsdon, C., & Harris, P. (2015). GWmodel: an R Package for exploring Spatial Heterogeneity using Geographically Weighted Models. *Journal of Statistical Software*, 63(17), 1–50.

Gonzalez, F. (2007). *Fundamentos de Fotointerpretacion* (Segunda Ed). Bogota, Colombia: Editorial Escuela Colombiana de Ingeniería.

Gonzalez, J., & Ortiz, J. (2015). Comparación de Temperaturas de brillo de los sensores Landsat-8/TIRS y GOES13/Imager en el desierto de Sechura. *Comisión Nacional de Investigación y Desarrollo Aeroespacial*.

Guo, Y., Feng, N., Christopher, S. A., Kang, P., Zhan, F. B., & Hong, S. (2014). Satellite remote sensing of fine particulate matter (PM_{2.5}) air quality over Beijing using MODIS. *International Journal of Remote Sensing*, 35(17), 6522–6544. <https://doi.org/10.1080/01431161.2014.958245>

Gutierrez, C., & Muñoz, A. (2006). *TELEDETECCION: NOCIONES Y APLICACIONES*.

España, Salamanca: Universidad de Salamanca.

Haamed, S., & Hasan, G. (2014). Estimation of PM10 Concentration using Ground Measurements and Landsat 8 OLI Satellite Image. *Journal of Geophysics & Remote Sensing*, 2(3), 1–6. <https://doi.org/http://doi.org/10.4172/2169-0049.1000120>

Harris, P., Brunson, C., & Fotheringham, A. (2011). Links, comparisons and extensions of the geographically weighted regression model when used as a spatial predictor. *Stochastic Environmental Research and Risk Assessment*, 25, 123–138.

Harris, P., Fotheringham, A., Crespo, R., & Charlton, M. (2010). The use of geographically weighted regression for spatial prediction: an evaluation of models using simulated data sets. *Mathematical Geosciences*, 42, 657–680.

Harris, P., & Juggins, S. (2011). Estimating freshwater critical load exceedance data for Great Britain using space-varying relationship models. *Mathematical Geosciences*, 43, 265–292.

Hernandez, M. (2007). *Epidemiología: diseño y análisis de estudios*. (EDITORIAL MEDICA PANAMERICA, Ed.) (PRIMERA ED). MEXICO , MEXICO DF.

Huete, A. (1988). Índice de vegetación ajustado al suelo (SAVI). *Teledetección Del Entorno*, 25(3), 295–309. [https://doi.org/https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/https://doi.org/10.1016/0034-4257(88)90106-X)

IGN. (2016). Modelo Digital de Elevaciones de la República Argentina, 32.

Instituto Nacional de Estadística y Geografía (INEGI). (2014). *Ficha técnica TERRA AQUA*. Retrieved from http://www.inegi.org.mx/geo/contenidos/imgpercepcion/imgsatelite/doc/aspectos_tecnicos_de_imagenes_modis.pdf

Jimenez, H. (2010). Metodología para el rellenado de las imágenes Landsat 7 ETM+ SLC-

- Off. In R. Estrada, G. Morales, N. Ramos, S. Duverger, & I. Garcia (Eds.), *Agencia de Medio Ambiente*. Habana, Cuba. Retrieved from <https://es-la.facebook.com/notes/giseros-en-facebook/metodología-para-el-rellenado-de-las-imágenes-landsat-7-etm-slc-off/364091260293917/>
- Jones, H. (2010). *SENSORES REMOTOS DE VEGETACION PRINCIPIOS TECNICOS Y APLICACIONES*. NEW YORK, ESTADOS UNIDOS: UNIVERSIDAD DE OXFORD.
- Kim, B. (2015). Understanding Diagnostic Plots for Linear Regression Analysis | University of Virginia Library Research Data Services + Sciences. Retrieved May 27, 2018, from <http://data.library.virginia.edu/diagnostic-plots/>
- Krajewski, L. (2000). *ADMINISTRACION DE OPERACIONES: ESTRATEGIA Y ANALISIS*. Mexico: Prentice Hall.
- LACEY JOEL. (2004). *GUIA COMPLETA DE IMAGEN DIGITAL CONCEPTOS BASICOS MEJORA DE LA IMAGEN* (Primera Ed). Barcelona España: The Ilex Press Limited.
- Li, F., Jackson, T., Kustas, W., Schmugge, T., French, A., BINDLISH, R., & COSH, M. (2004). Deriving land surface temp. from Landsat 5 and 7 during SMEX02 /SMACEX. *Remote Sensing of Environment*, 92(4), 521–534.
- Li, Z., Wu, H., Wang, N., Qiu, S., Sobrino, J., Wan, Z., & Yan, G. (2013). Land surface emissivity retrieval from satellite data. *International Journal of Remote Sensing*, 9(34), 3084–3127. Retrieved from <https://www.tandfonline.com/doi/pdf/10.1080/01431161.2012.716540?needAccess=true>
- Lira, J. (2011). *Percepcion Remota* (Segunda Ed). Mexico: Universidad Nacional

Autonoma de Mexico.

Mart, G. (2010). PROTOCOLO PARA LA OBTENCIÓN DE LA TEMPERATURA DE LA SUPERFICIE TERRESTRE A PARTIR DE DATOS LANDSAT y MODIS.

Martinez, R., Tuya, L., Martinez, M., Perez, A., & Canovas, A. (2009). EL COEFICIENTE DE CORRELACION DE LOS RANGOS DE SPEARMAN CARACTERIZACION. *Rev Haban Cienc Méd La Habana*, VIII(2). Retrieved from <http://scielo.sld.cu/pdf/rhcm/v8n2/rhcm17209.pdf>

MAS, J.-F. (2011). *Aplicaciones del sensor MODIS para el monitoreo del territorio. Journal of Chemical Information and Modeling* (Vol. 53). <https://doi.org/10.1017/CBO9781107415324.004>

McCune, & Grace. (2002). Ajustes de datos: transformación de datos, 23.

McFeeters, S. (1996). . The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *Remote Sensing of Environment*, 17, 1425–1432.

Ministerio del Ambiente. (2010). Plan Nacional de Calidad del Aire. *Ministerio Del Medio Ambiente, I*(Reintegración Comunitaria), 5–90.

Ministerio del Ambiente. (2011). *Norma de Calidad del Aire*. Retrieved from [https://www.minambiente.gov.co/images/normativa/app/resoluciones/bf-Resolucion 610 de 2010 - Calidad del Aire.pdf](https://www.minambiente.gov.co/images/normativa/app/resoluciones/bf-Resolucion%20610%20de%202010%20-%20Calidad%20del%20Aire.pdf)

Minitab. (2017). Residual plots for Fit Regression Model. Retrieved from <https://support.minitab.com/en-us/minitab/18/help-and-how-to/modeling-statistics/regression/how-to/fit-regression-model/interpret-the-results/all-statistics-and-graphs/residual-plots/>

Modenes, J., & Villarraga, H. (2014). Variación espacial de los factores asociados a la migración interna en España ¿Influye la presencia de población extranjera. XIV

Congreso Nacional de Población, AGE. Sevilla-, 551–528.

Moran, M., Slater, P., & Teillet, P. (1992). Evaluation of simplified procedures for retrieval of land surface reflectance factors from satellite sensor output. *Remote Sensing of Environment*, 41, 169–184.

Moreno, A. (2008). *Sistemas y Analisis de la Informacion Geografica Manual de Autoaprendizaje con Arcgis* (SEGUNDA ED). MEXICO , MEXICO DF: ALFAOMEGA GRUPO EDITOR ,S.A. DE C.V.

Mou, Y., Zhou, L., You, X., Lu, Y., Chen, W., & Zhao, X. (2017). Multiview partial least squares. *Chemometrics and Intelligent Laboratory Systems*, 160(September 2016), 13–21. <https://doi.org/10.1016/j.chemolab.2016.10.013>

Museo Ecuatoriano de Ciencias Naturales. (2010). *Áreas Naturales Del Distrito Metropolitano De Quito: Diagnóstico Bioecológico Y Socioambiental*. (P. M. Valenzuela, M. A. Benavides, & A. Loza, Eds.), *Museo Ecuatoriano de Ciencias Naturales (MECN)* (Vol. 1). DISTRITO METROPOLITANO DE QUITO: SECRETARÍA DE AMBIENTE (SA).

National Aeronautics and Space Administration. (2016). *LANDSAT 7 SCIENCE DATA USERS HANDBOOK*. DACOTA, ESTADOS UNIDOS: NATIONAL AERONAUTICS AND SPACE ADMINISTRATION.

National Institute of Standards and Technology. (2015). Spread Location Plot. Retrieved May 27, 2018, from <https://www.itl.nist.gov/div898/software/dataplot/refman1/auxillar/slplot.htm>

Ngadi, M., Prasher, S., Abdel-Nour, N., Ngadi, M., Prasher, S., & Karimi, Y. (2009). Combined Maximum R2 and Partial Least Squares Method for Wavelengths Selection and Analysis of Spectroscopic Data. *Article in International Journal of*

- Poultry Science International Journal of Poultry Science*, 8(2), 170–178.
<https://doi.org/10.3923/ijps.2009.170.178>
- Organizacion Mundial de la Salud. (2018). Calidad del aire ambiente (exterior) y salud. Retrieved July 16, 2018, from [http://www.who.int/es/news-room/fact-sheets/detail/ambient-\(outdoor\)-air-quality-and-health](http://www.who.int/es/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health)
- Penny, W., Kiebel, S., & Friston, K. (2003). Variational Bayesian Inference for fMRI time series. *NeuroImage*, 3(19), 727–741.
- Pons, X. (2003). Landsat 8 Novedades y posibilidades. Retrieved from https://blogpnt.files.wordpress.com/2009/06/xavierpons_sistema_landsat8.pdf
- Pope, C. A., Thun, M. J., Namboodiri, M. M., Dockery, D. W., Evans, J. S., Speizer, F. E., & Heath, C. W. (1995). Particulate Air Pollution as a Predictor of Mortality in a Prospective Study of U.S. Adults. *American Journal of Respiratory and Critical Care Medicine*, 151(3_pt_1), 669–674.
https://doi.org/10.1164/ajrccm/151.3_Pt_1.669
- Rodríguez, L. M. S., Jaramillo, L. A. E., & Capote, P. A. (2010). Estimación de un índice de calidad ambiental urbano, a partir de imágenes de satélite. *Revista de Geografía Norte Grande*, 95(45), 77–95. <https://doi.org/10.4067/S0718-34022010000100006>
- Romieu, I., Gouveia, N., Cifuentes, L. A., de Leon, A. P., Junger, W., Vera, J., ... HEI Health Review Committee. (2012). Multicity study of air pollution and mortality in Latin America (the ESCALA study). *Research Report (Health Effects Institute)*, (171), 5–86. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/23311234>
- Sakamoto, Y., & Kitagawa, G. (1987). Akaike Information Criterion Statistics. *Kluwer Academic Publishers*, 270–271.
- Serrano, R. (2003). *Introducción al análisis de datos experimentales: tratamiento de datos*

- en bioensayos*. España: Universidad Jaume.
- Servicio Geológico de los Estados Unidos. (2018). Landsat Science Products | Landsat Missions. Retrieved July 16, 2018, from <https://landsat.usgs.gov/landsat-science-data-products>
- Skokovic, D., Sobrino, J., Jimenez, J., Soria, G., Julien, Y., Mattar, C., & Jordi, C. (2014). *Calibration and Validation of Land Surface Temperature for Landsat 8 – TIRS Sensor* (Land produ).
- Sobrino, J., Jimenez, J., Soria, G., Guanter, L., Moreno, J., Plaza, A., & Martinez, P. (2008). Land surface emissivity retrieval from different VNIR and TIR sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 2(46), 316–327.
- Sobrino, J., Raissouni, A., Oliosio, A., Lopez, M., & Dempere, M. (2000). *Teledeteccion*. Valencia, España: Universidad de Valencia.
- Sol, 90. (2012). *Gran atlas de ciencia inventos*. Barcelona, Buenos Aires: Encyclopedia Britanica.
- Song, W., Jia, H., Huang, J., & Zhang, Y. (2014). A satellite-based geographically weighted regression model for regional PM_{2.5} estimation over the Pearl River Delta region in China. *Remote Sensing of Environment*, 154, 1–7. <https://doi.org/10.1016/J.RSE.2014.08.008>
- Tanre, D., Deroo, P., Duhaut, P., Herman, M., Morcrette, J., Perbos, J., & Deschamps, P. (1986). Simulation of the Satellite Signal in the Solar Spectrum (5S). *Laboratoire d'Optique Atmosphérique, Université Des Sciences et Techniques de Lille*.
- Tucker, C. (1979). Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *Remote Sensing of Environment*, 8, 127–150.
- Universidad de Murcia. (2003). Correcciones a las imágenes de satélites. *Apuntes de La*

- Asignatura Teledetección En Geografía*, 79–88. <https://doi.org/Universidad de Murcia>
- Valiente, L., & Herranz, I. (2010). *Bioestadística sin dificultades matemáticas*. Madrid, Buenos Aires, Mexico: Diaz de Santos.
- Vargas-Cuentas, N. I., Roman-Gonzalez, A., Mantari, A. A., & Muñoz, L. A. (2018). Chagas disease study using satellite image processing: A Bolivian case. *Acta Astronautica*, 144(December 2017), 216–224. <https://doi.org/10.1016/j.actaastro.2017.12.039>
- Vargas, N., & Roman-Gonzalez, A. (2012). Tecnología Aeroespacial en el Mundo. *Tecnología Aeroespacial En El Mundo*, 1(1), 48–52. <https://doi.org/hal-00742198v2>
- Wan, Z., & Li, Z. (1997). A Physics-Based Algorithm for Retrieving Land-Surface Emissivity and Temperature from EOS/MODIS Data. *IEEE Transactions on Geoscience and Remote Sensing*, 4(35), 980–996.
- Wu, J., Wang, D., & Bauer, M. (2005). Image-based atmospheric correction of QuickBird imagery of Minnesota cropland. *Remote Sensing of Environment*, 99, 315–325. Retrieved from https://pdfs.semanticscholar.org/1dd8/5b98d9c09ae994ed09f47853a92da149ef81.pdf?_ga=2.244025606.2049974184.1533402349-2131462951.1533402349
- Xia, L., Zhao, F., Chen, L., Zhang, R., Mao, K., Kylling, A., & Ying, M. (2018). Comparación del rendimiento de los canales cirros de cirros MODIS y VIIRS de 1,38 μm con los datos de libRadtran y CALIOP. *Teledetección Del Entorno*, 206(0034-4257), 363–374.
- Yoram, J., & Kaufman, D. (1992). Índice de vegetación resistente a la intemperie (ARVI) para EOS-MODIS. *TRANSACCIONES IEEE SOBRE LA GEOCIENCIA Y LA*

SENSACIÓN REMOTA, 30.

Zhang, T., Gong, W., Zhu, Z., Sun, K., Huang, Y., Ji, Y., & Talbot, R. W. (2016). Semi-Physical Estimates of National-Scale PM 10 Concentrations in China Using a Satellite-Based Geographically Weighted Regression Model. *Mapping and Remote Sensing, Wuhan University*. <https://doi.org/10.3390/atmos7070088>

8. ANEXOS

ANEXO A. Coordenadas de las Estaciones Automáticas y Pasivas del Distrito Metropolitano de Quito.

Tabla 26 Coordenadas de las Estaciones Automáticas y Pasivas del Distrito Metropolitano de Quito.

Nombre de la estación de la REMMAQ	Coordenadas Geográficas	Equipamiento
Carapungo	78°26'50" W, 0°5'54" S	SO ₂ , CO, NO _x , PAR, MET
Cotocollao	78°29'50"W, 0°6'28" S	SO ₂ , CO, O ₃ , NO _x , PM ₁₀ ,
Jipijapa	78°28'48" W, 0°09'36" S	SO ₂ , CO, NO _x , PM _{2.5} , PM ₁₀ ,
Belisario	78°29'24" W, 0°10'48" S	SO ₂ , CO, O ₃ , NO _x , PM _{2.5} ,
El Camal	78°30'36" W, 0°15'00" S	SO ₂ , CO, O ₃ , NO _x , PM _{2.5} ,
San Antonio	78°26'42" O, 0°00'30" S	PM _{2.5} , PM ₁₀
Guamaní	78°33'5" W, 0°19'51" S	CO, NO _x , O ₃ , PTS
Tumbaco	78°24'00" W, 0°12'36" S	SO ₂ , O ₃ , MET
Los Chillos	78°27'36" W, 0°18'00" S	O ₃ , PM ₁₀ , MET
Tababela	78°21'56" O, 0°08'08" S	PM _{2.5} , PM ₁₀ , PTS

Fuente: Secretaria del Ambiente (2010). Estaciones automáticas y pasivas de la Red Metropolitana de Calidad de Aire. Disponible en <http://www.quitoambiente.gob.ec/ambiente/index.php/los-chillos>

Anexo B. Corrección radiométrica de imagen satelital para el sensor “Landsat 7”

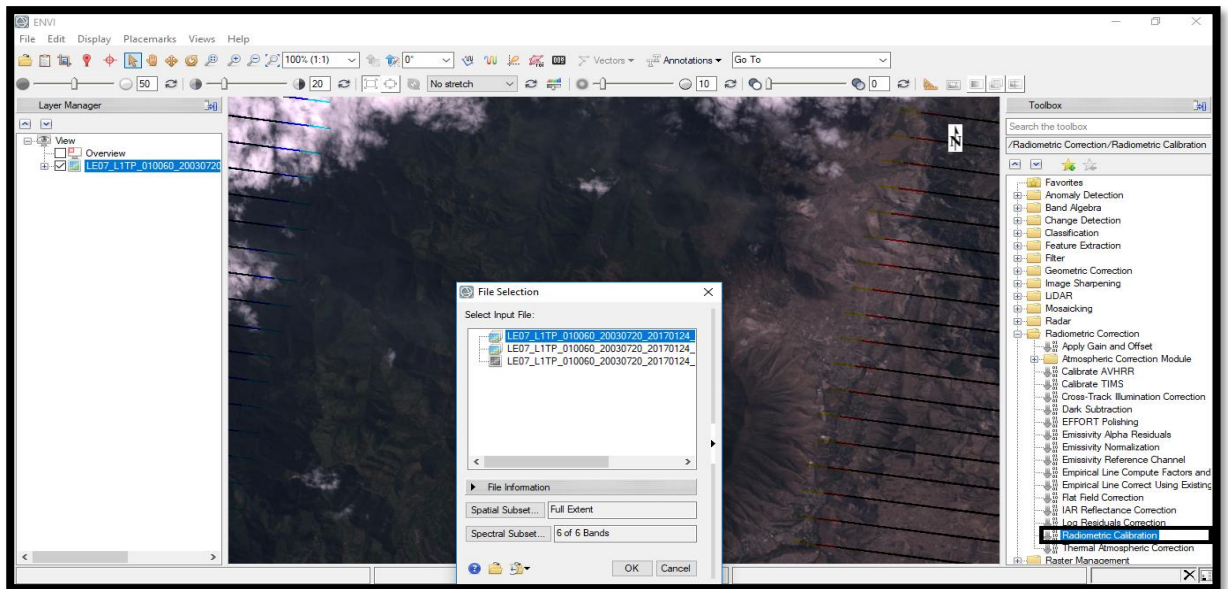


Figura 59. Aplicación de herramienta Radiometric Calibration con archivo Geotiff with MTL
Elaborado por: Torres N., Vivanco V., 2018

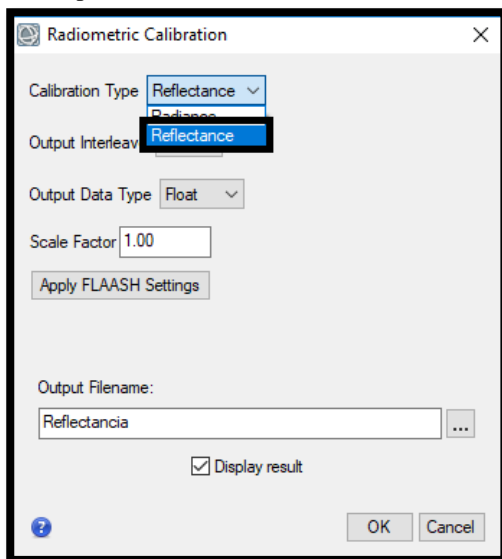


Figura 60. Calibración de la imagen satelital
Elaborado por: Torres N., Vivanco V., 2018




Figura 61. Imagen satelital luego de corrección radiométrica
Elaborado por: Torres N., Vivanco V., 2018

Anexo C. Histograma luego de aplicar Dark Subtraction

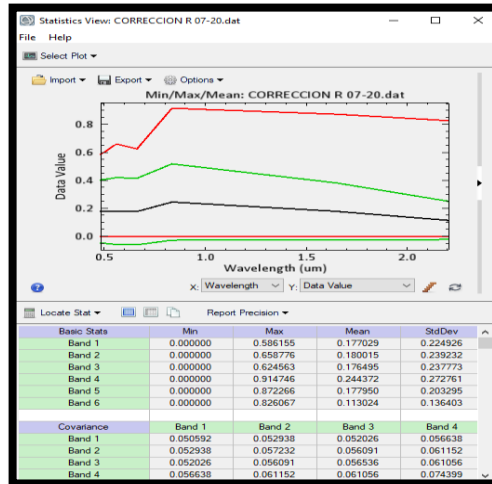


Figura 62. Valores obtenidos del histograma
Elaborado por: Torres N., Vivanco V., 2018

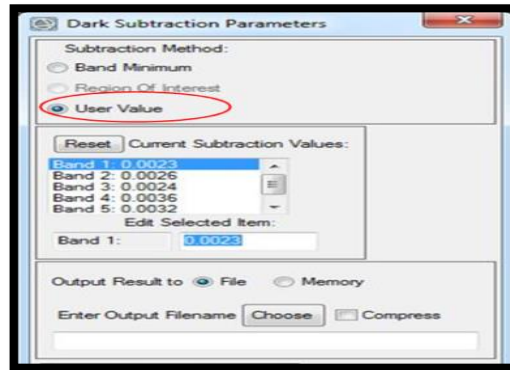


Figura 63. Parámetros de Dark Subtraction
Elaborado por: Torres N., Vivanco V., 2018

ANEXO D. Bandas del espectro electromagnético y resolución espacial de sensores

Tabla 27. Bandas del espectro electromagnético (microondas)

Banda espectral	Longitud de onda	Denominación de la banda
Visible	(0,4 – 0,7) μm	VIS
Infrarrojo próximo	(0,7 – 1,3) μm	NIR
Infrarrojo corto	(1,3 – 3) μm	SWIR
Infrarrojo medio	(3 – 5) μm	MWIR
Infrarrojo térmico	(6 – 15) μm	TIR

Fuente: Arozarena (2016). Bandas espectrales.

Tabla 28. Resolución espacial de sensores

Satélite	Sensor	Resolución Espacial (m)
QUICKBIRD		0,61
IKONOS		1
ORBVUEW		1
SPOT 5		2,5
SPOT 3	HRV pan	10
LANDSAT 7	ETM+ pan	15
LANDSAT 5	TM pan	30
MOS	VTIR	900
NOAA	AVHRR	1 100
METEOSAT	VISSRR	5 000

Fuente: Pérez, C & Muñoz, A. (2006). Introducción a la Teledetección Espacial. Disponible en: https://books.google.com.ec/books?id=SfrGxbO1DT0C&pg=PA8&dq=resoluci%C3%B3n+espacial&hl=es419&sa=X&ved=0ahUKEwiPo9Cf5ajZAhUG2VMKHU_9AMkQ6AEILzAC#v=onepage&q=resoluci%C3%B3n%20espacial&f=false

ANEXO E. Características principales de los sensores más utilizados en Teledetección y Bandas espectrales “Landsat 7”

Tabla 29. Bandas espectrales “Landsat 7”

Banda	Nombre	Longitud de onda (μm)	Resolución (m)
1	Azul	0,452 – 0,52	30
2	Verde	0,52 – 0,60	30
3	Rojo	0,63 – 0,69	30
4	Infrarrojo cercano (NIR)	0,77 – 0,90	30
5	Infrarrojo de onda corta 1 (SWIR 1)	1,55 – 1,75	30
6	TIR	10,40 – 12,50	30/60
7	Infrarrojo de onda corta 2 (SWIR 2)	2,09 – 2,35	30
8	Pancromática	0,52 – 0,90	15

Fuente: Servicio Geológico de los Estados Unidos (2013). Características de Landsat 7. Disponible en <https://landsat.usgs.gov/landsat-7-history>

Tabla 30. Características de los principales sensores utilizados en teledetección

Sensor	Res. Espacial	Tamaño de imagen	de Res. Temporal	Res. Radiométrica	Res. Espectral
Landsat	30 m	185*185km	16 días	256 ND	3 Vis 3 Ir 1 It
MODIS	250– 100 m	2330*2330km	1 día	1024 ND	36 bandas

Fuente: Chuvieco, E. (2006). Resolución espacial en los principales sensores.

ANEXO F. Bandas espectrales que conforman al sensor "MODIS" y "Landsat 8"

Tabla 31. Bandas espectrales “Landsat 8”

Banda	Nombre	Longitud de onda (μm)	Resolución (m)
1	Costera – Aerosoles	0,435 – 0,451	30
2	Azul	0,452 – 0,512	30
3	Verde	0,533 – 0,590	30
4	Rojo	0,636 – 0,673	30
5	Infrarrojo cercano (NIR)	0,851 – 0,879	30
6	Infrarrojo de onda corta 1(SWIR 1)	1,566 – 1,651	30
7	Infrarrojo de onda corta 2(SWIR 2)	2,107 – 2,294	30
8	Pancromática	0,503 – 0,676	15
9	Cirrus	1,363 – 1,384	30
10	(TIR 1)	10,60 – 11,19	100
11	(TIR 2)	11,50 – 12,51	100

Fuente: Servicio Geológico de los Estados Unidos (2013). Características de Landsat 8. Disponible en <https://landsat.usgs.gov/landsat-8-mission>

Tabla 32. Bandas Espectrales “MODIS”

	Banda	Longitud de onda (μm)
Límites de Tierra/ Nubes/Aerosoles	1	620 – 670
	2	841 – 876
	3	459 – 479
Propiedades de Tierra/Nubes/Aerosoles	4	545 – 565
	5	1230 – 1250
	6	1628 – 1652
	7	2105 – 2155
	8	405 – 420
	9	438 – 448
	10	483 – 493
Color del océano /fitoplancton/biogeoquímica	11	526 – 536
	12	546 – 556
	13	662 – 672
	14	673 – 683
	15	743 – 753
	16	862 – 877
	17	890 – 920
Vapor del agua atmosférico	18	931 – 941
	19	915 – 965
Temperatura de la superficie /nubes	20	3,660 - 3,840
	21	3,929 – 3,989
Temperatura atmosférica	22	3,929 – 3,989
	23	4,020 – 4,080
	24	4,433 – 4,498
	25	4,482 – 4,549
Vapor de agua de las nubes /Cirrus		

Propiedades de las nubes	27	6,535 – 6,895 1	
	28	7,175 – 7,475	
	29	8,400 – 8,700	
	30	9,580 – 9,880	
Temperatura de la superficie/nubes	31	10,780 - 11,280	
	32	11,770 - 12,270	
	Altitud de las nubes	33	13,185 - 13,485
		34	13,485 - 13,785
35		13,785 - 14,085	
36		14,085 - 14,385	

Fuente: Land Processes Distributed Active Archive Center (2013). Características de Sensor MODIS. Disponible en https://lpdaac.usgs.gov/dataset_discovery/modis