

UCUENCA

Facultad de Ciencias Químicas

Carrera de Ingeniería Ambiental

**RELACIÓN ENTRE LA TEMPERATURA SUPERFICIAL Y LOS GASES DE
EFECTO INVERNADERO EN EL ECUADOR CONTINENTAL DURANTE 2019**

Trabajo de titulación previo a la
obtención del título de Ingeniero
Ambiental

Autores:

Camila Elizabeth Vega Cuesta

CI: 0104827225

Correo electrónico: camila.vega1997@gmail.com

Luis Fernando Loja Naspud

CI: 0103893681

Correo electrónico: fernando29loja@hotmail.es

Tutor:

Julio Danilo Mejía Coronel

CI: 0103638581

Cuenca, Ecuador

21-julio-2022

RESUMEN

Este estudio abordó el tema de la relación entre la temperatura superficial y los gases de efecto invernadero (GEI) en el Ecuador Continental durante 2019 empleando el satélite Sentinel 5P. Los GEI han estado en la atmósfera durante mucho tiempo permitiendo que el planeta sea habitable, sin embargo, debido a las actividades humanas, estos gases han ido en aumento influyendo en la calidad del aire y el cambio climático. Por tal razón, se presenta la necesidad de conocer a mayor detalle las concentraciones de estos gases, no obstante, no se han realizado estudios empleando Sentinel 5P en el Ecuador.

El objetivo del estudio fue determinar si existe una relación entre la temperatura superficial en zonas latitudinales y concentraciones de GEI. Los GEI utilizados fueron NO_2 , SO_2 , y O_3 , otro gas estudiado fue el CO , el cual es un GEI indirecto, para lo cual se utilizó el sensor remoto Sentinel 5P y las estaciones meteorológicas del INAMHI, las cuales fueron analizadas mediante los métodos de interpolación IDW y Kriging Simple, generando mejores resultados el IDW. Posteriormente imágenes IDW y GEI fueron analizados mediante los procesos estadísticos Regresión Lineal Simple y Regresión Lineal Múltiple.

De acuerdo con el análisis realizado, se concluye que existe una relación baja entre los GEI y la temperatura superficial cuando los gases se analizan individualmente, por otra parte, al analizar los datos como un conjunto estos demostraron tener mayor influencia en la temperatura. Este trabajo servirá de base para poder realizar estudios más complejos en la región andina utilizando los GEI y la temperatura superficial.

Palabras Clave: Gases efecto invernadero. Sensores remotos. Calidad del aire. Sentinel 5P. Ecuador continental.

ABSTRACT

This study examined the relationship between surface temperature and greenhouse gases (GHGs) in the Ecuadorian continent in 2019, using the Sentinel 5P satellite. GHGs have been in the atmosphere for a long time allowing the planet to be habitable; however, due to human activities, these gases have been increasing, influencing air quality and climate change. For this reason, there is a necessity to know in greater detail the concentrations of these gases; however, no studies have been carried out using Sentinel 5P in Ecuador.

The purpose of the study was to determine whether the surface air temperature is higher in areas with elevated GHG concentrations. The GHGs analyzed were NO₂, SO₂, and O₃, another gas studied was CO, which is an indirect GHGs, for which the Sentinel 5P remote sensor and the INAMHI meteorological stations were used. The aforementioned gases were analyzed using the IDW and Simple Kriging interpolation methods, given the IDW method better results. Subsequently, the IDW method and the GHG were analyzed using the Simple Linear Regression and Multiple Linear Regression methods.

According to the analysis carried out, it was concluded that there was a low relationship between GHG and Surface Temperature when the gases were analyzed individually. On the other hand, when all gases were analyzed together, the results showed a higher influence on temperature.

This study will serve to carry out more complex studies in the Andean region using GHG and surface temperature.

Keywords: Greenhouse gases. Remote Sensing. Air quality. Sentinel 5P. Continental Ecuador. .

ÍNDICE DE CONTENIDO

RESUMEN.....	2
ABSTRACT.....	2
ÍNDICE DE FIGURAS.....	7
ÍNDICE DE TABLAS.....	9
ÍNDICE DE ECUACIONES.....	10
AGRADECIMIENTOS.....	15
1 INTRODUCCIÓN.....	16
1.1 Antecedentes.....	16
1.2 Problemática.....	18
1.3 Justificación.....	21
1.4 Objetivos.....	22
1.4.1 Objetivo General.....	22
1.4.2 Objetivo Específico.....	22
2 FUNDAMENTO TEÓRICO.....	23
2.1 La Atmósfera.....	23
2.1.1 Composición y Estructura de la Atmósfera.....	23
2.1.2 Descripción atmosférica sobre el territorio ecuatoriano.....	25
2.2 La Calidad del Aire.....	25
2.2.1 Calidad del Aire del Ecuador.....	25
2.2.2 Contaminantes Atmosféricos.....	26
2.2.2.1 Dióxido de Nitrógeno (NO ₂).....	26
2.2.2.2 Dióxido de Azufre (SO ₂).....	26
2.2.2.3 Monóxido de Carbono (CO).....	27
2.2.2.4 Ozono (O ₃).....	27
2.3 La Temperatura Superficial.....	28
2.4 Georeferenciación.....	28
2.5 Sistemas de Información Geográfica.....	28
2.5.1 Mapas.....	29
2.5.2 Datos.....	29
2.5.3 Análisis de Datos.....	30
2.6 Teledetección.....	30
2.7 Google Earth Engine (GEE).....	30
2.7.1 Descripción General de GEE.....	31

UCUENCA

2.7.2	Catálogo de Datos Sentinel-5P.	31
2.7.3	TROPOMI.	32
3	MATERIALES Y MÉTODOS.	33
3.1	Descripción de la Zona de Estudio.	33
3.2	Metodología General.	34
3.2.1	Programas Utilizados.	34
3.2.2	Metodología General.	35
3.3	Obtención de datos de Temperatura.	36
3.3.1	Obtención de imágenes Interpoladas.	37
3.3.1.1	Vecino Más Próximo (IDW).	37
3.3.1.2	Kriging Simple.	38
3.3.2	Análisis de las imágenes de la Temperatura.	39
3.3.2.1	Error Absoluto Medio (MAE).	39
3.3.2.2	Raíz de la Desviación Cuadrática Media (RMSD).	39
3.3.2.3	Error Porcentual Medio Absoluto (MAPE).	40
3.3.2.4	Criterio de Información de Akaike (AIC)	40
3.4	Metodología de obtención de datos de TROPOMI Sentinel-5P.	41
3.4.1	Obtención de imágenes satelitales TROPOMI Sentinel-5P.	41
3.5	Relación entre la temperatura superficial del aire y la columna de GEI.	43
3.5.1	Regresión Simple.	43
3.5.2	Regresión Lineal Múltiple	44
3.5.3	Coefficiente de Determinación R^2	44
4	RESULTADOS Y DISCUSIÓN	46
4.1	RESULTADOS	46
4.1.1	Depuración de Datos	46
4.1.2	Datos de Temperatura.	49
4.1.2.1	Datos Mensuales de Temperatura.	49
4.1.2.2	Datos Anuales de Temperatura	55
4.1.3	Selección de Datos Interpolados.	55
4.1.4	Datos satelitales TROPOMI Sentinel-5P.	56
4.1.4.1	Concentraciones Mensuales de los diferentes gases de efecto invernadero.	56
4.1.4.2	Concentraciones Anuales de los diferentes gases de efecto invernadero.	76

UCUENCA

4.1.5	Relación entre la Temperatura y las Variables.	77
4.2	DISCUSIÓN.	80
4.2.1	Comparación entre los métodos IDW y Kriging Simple.	80
4.2.2	Relación entre la Temperatura y los Gases de Efecto Invernadero.	81
5	CONCLUSIONES Y RECOMENDACIONES.	84
5.1	CONCLUSIONES.	84
5.2	RECOMENDACIONES.	86
6	BIBLIOGRAFÍA.	87
7	ANEXOS.	94
7.1	Anexo 1: Comandos de obtención de imágenes de Google Earth Engine.	94
7.1.1	CO.	94
7.1.2	NO ₂	95
7.1.2.1	NO ₂ Total.	95
7.1.2.2	NO ₂ Troposférico.	96
7.1.2.3	NO ₂ Estratosférico.	97
7.1.3	O ₃	98
7.1.4	SO ₂	99
7.2	Anexo 2: Cálculo de correlaciones en R-Studio.	100
7.2.1	Librerías.	100
7.2.2	Cálculo de correlaciones.	101

ÍNDICE DE FIGURAS

Figura 1: TROPOMI	32
Figura 2: Zona de Estudio.	34
Figura 3: Metodología General.	35
Figura 4: Estaciones INAMHI primer filtro.....	46
Figura 5: Estaciones INAMHI.	48
Figura 6: Temperatura Promedio Mensual: IDW.	50
Figura 7: Temperatura Promedio Mensual: IDW.	51
Figura 8: Temperatura Promedio Mensual: Kriging Simple.....	53
Figura 9: Temperatura Promedio Mensual: Kriging Simple.....	54
Figura 10: Temperatura Promedio Anual.....	55
Figura 11: Concentraciones Mensuales de CO.	57
Figura 12: Concentraciones Mensuales de CO.	58
Figura 13: Concentraciones Mensuales de O ₃	59
Figura 14: Concentraciones Mensuales de O ₃	61
Figura 15: Concentraciones Mensuales de SO ₂ (Con Concentraciones Negativas).....	62
Figura 16: Concentraciones Mensuales de SO ₂ (Con Concentraciones Negativas).....	64
Figura 17: Concentraciones Mensuales de SO ₂ (Sin Concentraciones Negativas).....	65
Figura 18: Concentraciones Mensuales de SO ₂ (Sin Concentraciones Negativas).....	67

UCUENCA

Figura 19: Concentraciones Mensuales de NO₂ Troposférico (Con Concentraciones Negativas).....68

Figura 20: Concentraciones Mensuales de NO₂ Troposférico (Con Concentraciones Negativas).....69

Figura 21: Concentraciones Mensuales de NO₂ Troposférico (Sin Concentraciones Negativas).....70

Figura 22:Concentraciones Mensuales de NO₂ Troposférico (Sin Concentraciones Negativas).....71

Figura 23: Concentraciones Mensuales de NO₂ Estratosférico.72

Figura 24: Concentraciones Mensuales de NO₂ Estratosférico.73

Figura 25: Concentraciones Mensuales de NO₂ Total.....74

Figura 26: Concentraciones Mensuales de NO₂ Total.....75

Figura 27: Concentraciones de GEI Promedio Anual (Con Concentraciones Negativas).....76

Figura 28: Concentraciones de GEI Promedio Anual (Sin Concentraciones Negativas).....76

ÍNDICE DE TABLAS

Tabla 1: Programas a utilizarse en el desarrollo de la investigación	34
Tabla 2: Disponibilidad de imágenes	42
Tabla 3: Porcentaje de Vacíos	47
Tabla 4: Coeficientes.....	56
Tabla 5: Coeficiente R^2 : Regresión Lineal Simple	78
Tabla 6: Coeficiente R^2 : Regresión Lineal Múltiple	79

ÍNDICE DE ECUACIONES

Ecuación 1: Porcentaje de Valores Faltantes.	36
Ecuación 2: IDW.	38
Ecuación 3: Kriging Simple.....	38
Ecuación 4: Error Absoluto Medio.	39
Ecuación 5: Raíz de la Desviación Cuadrática Media.....	40
Ecuación 6: Error Porcentual Medio Absoluto.	40
Ecuación 7: Criterio de Información de Akaike.	41
Ecuación 8: Regresión Lineal Simple.	43
Ecuación 9: Regresión Lineal Múltiple.....	44
Ecuación 10: Coeficiente de Determinación R^2	44

Cláusula de Propiedad Intelectual

LUIS FERNANDO LOJA NASPUD, autor/a del trabajo de titulación "RELACIÓN ENTRE LA TEMPERATURA SUPERFICIAL Y LOS GASES DE EFECTO INVERNADERO EN EL ECUADOR CONTINENTAL DURANTE 2019", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor/a.

Cuenca, 21 de julio 2022



LUIS FERNANDO LOJA NASPUD

C.I: 010389368-1

Cláusula de Propiedad Intelectual

CAMILA ELIZABETH VEGA CUESTA, autora del trabajo de titulación "RELACIÓN ENTRE LA TEMPERATURA SUPERFICIAL Y LOS GASES DE EFECTO INVERNADERO EN EL ECUADOR CONTINENTAL DURANTE 2019", certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autora.

Cuenca, 21 de julio de 2022



CAMILA ELIZABETH VEGA CUESTA

C.I.: 010482722-5

Cláusula de licencia y autorización para publicación en el Repositorio Institucional

LUIS FERNANDO LOJA NASPUD en calidad de autor/a y titular de los derechos morales y patrimoniales del trabajo de titulación "RELACIÓN ENTRE LA TEMPERATURA SUPERFICIAL Y LOS GASES DE EFECTO INVERNADERO EN EL ECUADOR CONTINENTAL DURANTE 2019", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 21 de julio 2022



LUIS FERNANDO LOJA NASPUD

C.I: 010389368-1

Cláusula de licencia y autorización para publicación en el Repositorio Institucional

CAMILA ELIZABETH VEGA CUESTA en calidad de autora y titular de los derechos morales y patrimoniales del trabajo de titulación "RELACIÓN ENTRE LA TEMPERATURA SUPERFICIAL Y LOS GASES DE EFECTO INVERNADERO EN EL ECUADOR CONTINENTAL DURANTE 2019", de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio Institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 21 de Julio de 2022



CAMILA ELIZABETH VEGA CUESTA

C.I: 010482722-5

AGRADECIMIENTOS

A las personas que han sido el apoyo constante de superación personal y profesional en especial a los involucrados directamente en este estudio, Blgo. Danilo Mejía, Srta. Camila Vega, Ing. Darío Zhiña, dedicado a mi hija Monserrath, mi constante universal.

Luis Fernando Loja Naspud

Por medio de este trabajo agradezco a mis padres quienes siempre me han brindado su apoyo, y a esta noble institución que me abrió las puertas para cumplir con mis metas.

Camila Elizabeth Vega Cuesta

1 INTRODUCCIÓN.

Las actividades asociadas al desarrollo económico social e incluso al desarrollo político de los territorios han ido desembocando en el aumento de las concentraciones de gases de efecto invernadero provocando una afectación al clima de todo el planeta, en especial la concentración de dióxido de carbono que es el resultado principal de las actividades humanas para el desarrollo de los pueblos (Escobar, 1997).

El clima se ha mantenido constante en los últimos 10000 años después de la última glaciación, aunque el cambio climático se ha visto afectado en los últimos años, debido a la contaminación antrópica ya sea para la movilidad o para la industria, provocando el aceleramiento del efecto invernadero (Baethgen & Martino, 2000).

1.1 Antecedentes.

En el estudio realizado por (Zheng et al., 2019), realizado en China durante el periodo febrero 2018 a enero 2019, los autores concluyeron que los resultados muestran que la fluctuación mensual de la concentración de la columna troposférica de NO₂ tiene características obvias de "alto en invierno y bajo en verano", mientras que la distribución espacial forma un patrón "alto en el este y bajo en el oeste", delimitado por la línea Hu, la cual es una recta imaginaria que divide China. La comparación de los modelos de coeficiente de variación (CV) y autocorrelación espacial en dos tipos de escalas administrativas indica que, aunque la heterogeneidad espacial de la concentración de la columna de NO₂ se ve menos afectada por la escala observada, hay un "efecto retardado" de aproximadamente un mes en el proceso de fluctuación de la concentración de la columna NO₂. Además, el análisis de factores de impacto basado en Spatial Lag Model (SLM) y Geographic Weighted Regression (GWR) revela que existe una correlación positiva entre la intensidad de la

UCUENCA

luz nocturna, la proporción de industrias secundarias y terciarias y la concentración de la columna de NO₂. Además, para las regiones con grave contaminación por NO₂ en la llanura del norte de China, el consumo de electricidad de toda la sociedad y la propiedad de vehículos también desempeñan un papel positivo en el aumento de la concentración de la columna de NO₂.

En el estudio realizado por (Kaplan & Yigi, 2020), se planteó como objetivo utilizar datos satelitales de resolución relativamente alta para el monitoreo local de la calidad del aire / contaminación del aire e investigar la relación de los contaminantes con los datos geográficos y demográficos del área de análisis, en este estudio se emplearon datos de CO y NO₂, obtenidos a partir del satélite Sentinel-5P, adicionalmente se elaboraron estadísticas de población, modelos digitales de elevación y cobertura vegetal, utilizado para análisis geoespaciales y estadísticos. Los hallazgos muestran valores significativamente altos de CO y NO₂ en varias partes del área de estudio, especialmente altos valores de CO en los valles Vardar y Polog, y altos valores de NO₂ en las ciudades densamente pobladas. Según los análisis, existe una alta correlación positiva entre el NO₂ y las estadísticas de población ($r = 0,78$; $R^2 = 0,61$) y alta correlación negativa ($r = -0,9$; $R^2 = 0,80$) entre la altitud y los valores de CO del área de estudio. Los resultados generales de este estudio confirmaron la capacidad de los datos de Sentinel-5P TROPOMI para ser utilizados en el monitoreo de la calidad del aire y la contaminación del aire sobre áreas locales.

En el estudio realizado en Bogotá (Colombia) “por (Forero, 2019) se analizaron las imágenes del sensor TROPOMI del Satélite Sentinel-5P, calculando la correlación con las estaciones en tierra para dos gases que son CO y NO₂, en donde se presentaron correlaciones positivas, por otro lado, para el O₃ y SO₂, en los cuales se presentó una correlación entre las variables”.

UCUENCA

Se realizó un estudio en la península de Malasia “por (Rajab et al., 2011), en el cual se analizó la relación entre los gases de efecto invernadero y la temperatura superficial del aire mediante AIRS Data, para el periodo 2003-2008, en el cual concluyeron que el contaminante más significativo en relación con la temperatura superficial del aire para la época seca es el vapor de agua”.

En la ciudad de Helsinki en Finlandia se realizó un estudio comparativo del NO₂ entre el instrumento TROPOMI/Sentinel 5 Precursor con puntos en tierra, este fue uno de los primeros estudios de este tipo realizados, dando como resultado que el promedio de la variación es de menos del 10 %, y presenta una alta correlación con las observaciones terrestres. Lo cual parece demostrar la capacidad de TROPOMI para reproducir adecuadamente la variabilidad diaria y semanal.

Otro estudio similar en Lombardía al norte de Italia, realizado por (Oxoli et al., 2020), en el cual se buscó comparar las observaciones de las misiones Sentinel 5P con mediciones terrestres tradicionales para analizar sus correlaciones temporales y espaciales en toda la región. El estudio se centró principalmente en el NO₂ durante la temporada de pandemia, los resultados mostraron una fuerte correlación positiva entre los satélites y las mediciones en tierra.

1.2 Problemática.

La contaminación atmosférica ha ido en aumento debido a actividades como el desarrollo económico, urbanización, el consumo energético, el transporte, la automatización y a un alto crecimiento de la población. Todos estos factores han generado un aumento de los gases de efecto invernadero (GEI), estos gases siempre han estado presentes en la atmósfera, permitiendo que el planeta sea habitable, sin embargo en altas concentraciones han demostrado ser importantes debido a su impacto en el cambio climático, y a la mortalidad causada por problemas respiratorios,

UCUENCA

los cuales han aumentado en las últimas décadas a causa de la exposición de estos contaminantes (Ballester, 2005; Ballester et al., 2003; Bello et al., 2019; Oyarzún, 2010).

El dióxido de nitrógeno (NO_2) y el dióxido de azufre (SO_2), pueden afectar indirectamente a la vegetación mediante reacciones químicas en la atmósfera, debido a que estos anhídridos al unirse con el vapor de agua presente en la atmósfera generan ácidos fuertes como; el ácido sulfúrico (H_2SO_4) y el ácido nítrico (H_2NO_3), los cuales al precipitar afectan a las coberturas vegetales, y a la infraestructura urbana (García et al., 2006).

El ozono (O_3) a nivel estratosférico es beneficioso para el planeta, no obstante, a nivel troposférico es peligroso para la salud, la repetida exposición a bajas concentraciones produce estrés oxidativo (Bello et al., 2019).

El monóxido de carbono (CO) es conocido por su alta toxicidad para el ser humano, sus efectos agudos pueden incluir la muerte, sin embargo, sus efectos a largo plazo son desconocidos (Téllez et al., 2006).

A pesar de que el CO_2 no se va a estudiar en este trabajo debido a que el satélite no mide este gas, es importante conocerlo para entender mejor al metano (CH_4), debido a que en 1994 el Grupo Intergubernamental del Cambio Climático (IPCC por sus siglas en inglés) definió el concepto de Potencial de Calentamiento Global (PCG) de los diferentes gases tomando como referencia al CO_2 , se determinó que el PCG del CH_4 es de 21, es decir que una tonelada de CH_4 tendrá 21 veces más impacto ambiental que una de CO_2 en un periodo determinado de 100 años (Baethgen & Martino, 2000).

UCUENCA

El CH_4 es un gas que se encuentra en la naturaleza debido a la descomposición de la materia orgánica el cual es considerado un gas de efecto invernadero, con un potencial de calentamiento global 21 veces mayor al del CO_2 (Hernández, 2010). Sin embargo, este gas no será analizado debido a la escasez de datos presentado durante el periodo de estudio.

Adicionalmente, los GEI no solo causan daños al ambiente, sino que también generan daños a la salud, el aumento de NO_2 y SO_2 se ha visto relacionado con el aumento de la mortalidad debido a su capacidad de irritación de los alvéolos, y aumento de las afecciones pulmonares, como la bronquitis, el O_3 genera daño en las células epiteliales, alveolitis neutrofílica, etc. El CO puede reaccionar con la hemoglobina de la sangre siendo más reactivo que el oxígeno, formando la carboxihemoglobina que reduce la capacidad de la sangre de transportar oxígeno a los pulmones y tejidos (Oyarzún, 2010).

Cuando la temperatura corporal aumenta en $1\text{ }^\circ\text{C}$ ya causa daño al organismo, y si la temperatura corporal llega a los $41\text{ }^\circ\text{C}$ puede ser mortal, además, entre los efectos causados tenemos calambres, agotamiento y síncope, hasta la forma más grave, que es el golpe de calor. Todos estos efectos se producen cuando los mecanismos fisiológicos no pueden realizar una correcta regulación del calor, por lo que la temperatura central aumenta y las funciones mentales de la persona pueden verse afectadas, con lo que no podría pedir auxilio y puede incluso accidentarse (González et al., 2013).

Por lo expuesto, se presenta la necesidad de conocer la información sobre las concentraciones de estos gases, para la gestión de la calidad del aire, y la posterior toma de decisiones. Adicionalmente el uso del sensor Sentinel-5P, presenta un beneficio económico al ser información actualizada y de acceso público que está

UCUENCA

avalado por la Agencia Espacial Europea (ESA). Sin embargo, no se han realizado estudios empleando Sentinel-5P en el Ecuador continental, además no se ha comprobado su utilidad en los países andinos.

1.3 Justificación.

En el libro “Cambio climático: una visión desde México” de Martínez & Fernández, (2004), se dice que uno de los efectos visibles del deterioro ambiental es el cambio climático, cuando un parámetro meteorológico se desvía del valor medio de varios años se lo considera una anomalía climática, durante las últimas décadas estas anomalías se han visto incrementados por un fenómeno conocido como efecto invernadero, en general este fenómeno consiste en que la energía que es recibida por la tierra del sol (radiación de onda corta) es redirigida al espacio (radiación de onda larga), sin embargo por la presencia de los gases de efecto invernadero (GEI) esta energía saliente de la tierra es redirigida hacia la tierra nuevamente, y de este modo la temperatura superficial va en aumento, algunos autores consideran que el término efecto invernadero no es correcto, pues un invernadero se calienta por impedir la convección y no por atrapar la radiación, por lo que sugieren el uso del término efecto atmósfera.

La efectividad de la medición de gases mediante sensores remotos se ha comprobado en otros países, por lo que, este trabajo verificará su utilidad para el Ecuador continental, el cual posee la Cordillera de los Andes. Además, se estudiará la relación entre la temperatura superficial y el perfil vertical de los gases de efecto invernadero que no han sido estudiados antes en el país.

Por tanto, esta investigación no solo comprobará la efectividad del sensor remoto Sentinel-5P TROPOMI, para la medición de concentraciones de contaminantes al aire ambiente en el Ecuador continental, sino adicionalmente,

UCUENCA

permitirá un conocimiento sobre los niveles de monóxido de carbono (CO), ozono (O₃), dióxido de nitrógeno (NO₂) y dióxido de azufre (SO₂), información que es de gran utilidad para la planificación urbana y toma de decisiones.

1.4 Objetivos.

1.4.1 *Objetivo General.*

Determinar si existe una relación entre la temperatura superficial en zonas latitudinales y las concentraciones de Gases de Efecto Invernadero.

1.4.2 *Objetivo Específico.*

- Contrastar los métodos de interpolación IDW y Kriging Simple.
- Analizar los GEI obtenidos a partir de Sentinel 5P.
- Determinar la influencia individual de cada GEI con respecto a la

Temperatura.

- Determinar la influencia colectiva de los GEI con respecto a la

Temperatura.

- Determinar la influencia de las concentraciones negativas de SO₂

y NO₂ Troposférico.

2 FUNDAMENTO TEÓRICO.

Para la realización del presente trabajo de investigación será necesario el empleo de diversas categorías relacionadas con el estudio de los Gases de Efecto Invernadero (GEI), con la finalidad de identificar su relación con la temperatura superficial en zonas latitudinales. De acuerdo con Benavides & León, (2007) los GEI *“son los componentes gaseosos de la atmósfera, tanto naturales como antropogénicos, que absorben y emiten radiación en determinadas longitudes de onda del espectro de radiación infrarroja emitido por la superficie de la Tierra, la atmósfera y las nubes”*. Debido a que la efectividad de la medición de gases mediante sensores remotos se ha comprobado en otros países, este trabajo verificará su utilidad para el Ecuador Continental.

2.1 La Atmósfera.

Es una delgada capa gaseosa que recubre a la Tierra, esta capa se ve formada por los gases y por partículas sólidas y líquidas en suspensión que se ven atraídos por la gravedad de dicho cuerpo, a pesar de ser una capa delgada es vital para la supervivencia de la vida en el planeta, puesto que en ella residen los gases fundamentales para el desarrollo de la mayor de la vida (Caballero et al., 2007).

2.1.1 Composición y Estructura de la Atmósfera.

La Atmósfera Terrestre es un fluido constituido principalmente por dos gases; Nitrógeno (N_2) en un 79% y Oxígeno (O_2) en un 20%, en el 1% restante se encuentran varios gases, de los cuales los dos principales son Argón (Ar) en un 0.9% y Dióxido de Carbono (CO_2) en un 0.03%. Sin embargo, desde la formación de la tierra la composición de la atmósfera no ha sido constante, sino que es el resultado de distintas interacciones que se han formado a lo largo de los años (Graedel, 2012).

UCUENCA

La atmósfera como ya se ha dicho es una capa gaseosa que alcanza unos 10.000 km de distancia desde la superficie del planeta, en ella se producen todos los fenómenos climáticos y meteorológicos que afectan al planeta, si bien tiene un espesor de varias centenas de kilómetros cerca del 99% de su masa gaseosa se encuentra dentro de los primeros 30 km (Álvarez et al., 2020).

Según los autores Caballero et al., (2007) y Shepherd, (2000) la atmósfera se divide en varias capas de las cuales hablaremos a continuación:

La Tropósfera es la capa más cercana a la superficie terrestre, llegando a alcanzar una altura promedio de unos 12 km de alto, en esta capa ocurren los fenómenos atmosféricos. Es la capa más densa, y cálida, a pesar de que, en su límite exterior, denominado tropopausa, llega a alcanzar una temperatura de $-55\text{ }^{\circ}\text{C}$.

La Estratósfera es una capa que se encuentra entre los 10 y 50 km de altura, en esta capa se encuentra la denominada capa de ozono, también es la encargada de proteger a la tierra de los rayos UV. En ella su temperatura aumenta hasta llegar a los $0\text{ }^{\circ}\text{C}$ en la zona denominada estratopausa.

La Mesosfera es una capa que se extiende hasta los 80 km de altitud, en esta capa nuevamente disminuye la temperatura llegando a alcanzar los $-80\text{ }^{\circ}\text{C}$ hasta llegar a la mesopausa.

La Termósfera o también denominada Ionosfera es una capa que se extiende desde los 80 km hasta alcanzar los 800 km de altura, se caracteriza por tener un aire muy poco denso y por permitir la conducción de la electricidad, en esta capa predomina el nitrógeno, y su temperatura puede aumentar hasta los $1500\text{ }^{\circ}\text{C}$. Su límite exterior es la termopausa o ionopausa. La ionización ionosférica se produce y se estratifica aún más a través de la radiación solar, y la concentración máxima de ionización se produce en la región F ionosférica, la ionosfera juega un papel

UCUENCA

fundamental en las relaciones solar-terrestres, fusionando la influencia de arriba y abajo (Tsagouri, 2022).

La Exósfera es una capa que se extiende desde los 800 km a los 10.000 km de altura, es una capa poco densa que se encuentra en contacto con el exterior, siendo la zona en la que se pierden partículas que escapan al exterior.

2.1.2 Descripción atmosférica sobre el territorio ecuatoriano.

La composición atmosférica del Ecuador es similar a la de otros países, sin embargo, la distribución de ozono estratosférico sobre el territorio ecuatoriano hace que este tenga una mayor radiación solar en comparación con otros países, esto a su vez se ve influenciado por las emisiones generadas por los sectores productivos (Arboleda & Vásquez, 2021).

2.2 La Calidad del Aire.

El aire es una mezcla compleja de gases, principalmente oxígeno (O₂) y nitrógeno (N₂), que presenta la capacidad de diluir los contaminantes, una vez dicho esto, la calidad del aire o inmisión se entiende como la concentración de contaminante que llega a un receptor que no se encuentra cerca de la fuente de emisión (Matus C. & Lucero Ch., 2002).

2.2.1 Calidad del Aire del Ecuador.

El Ecuador cuenta con pocas investigaciones con respecto a la calidad del aire de manera global, por lo que no se puede hablar de un único resultado, sin embargo, las ciudades de Quito y Cuenca indican un nivel moderado de contaminación del aire, por otra parte, durante el 2020 se notaron cambios evidentes con respecto a la calidad del aire, debido a la pandemia la calidad del aire aumento en ambas ciudades (EMOV, 2021; Secretaría de Ambiente, 2020).

2.2.2 Contaminantes Atmosféricos.

Según Aránguez et al., (1999) se entiende por contaminantes atmosféricos a *“la presencia en el aire de materias o formas de energía que impliquen riesgo, daño o molestia grave para las personas y bienes de cualquier naturaleza”*.

Por su parte el Ministerio de Aire y Agua del Ecuador (MAAE, 2019) reconoce a un contaminante atmosférico como *“una sustancia o material emitido a la atmósfera, sea por actividad humana o por procesos naturales, y que afecta adversamente al hombre o al ambiente”*.

2.2.2.1 Dióxido de Nitrógeno (NO₂).

Es un gas incoloro, de fácil combustión y altamente tóxico, se considera que la principal fuente de emisión es la del sector automotor, siendo considerado como un factor de riesgo con respecto al desarrollo de enfermedades respiratorias (Pujadas, 2004).

Con respecto al desarrollo de enfermedades mencionado, esto se da debido a la capacidad corrosiva del NO₂ para irritar los alveolos pulmonares, adicionalmente, el NO₂ provoca daño agudo, inflamación e hiperreactividad bronquial, junto a un desequilibrio en la respuesta inmunitaria característico del asma (Gutiérrez et al., 2018).

2.2.2.2 Dióxido de Azufre (SO₂).

A bajas concentraciones es un gas incoloro e inodoro, sin embargo, en concentraciones más altas obtiene un olor acre. Su emisión procede principalmente de la combustión de combustibles fósiles ricos en azufre (Matus C. & Lucero Ch., 2002).

Varios estudios han demostrado la relación del SO₂ con el desarrollo de enfermedades bronquiales, adicionalmente los efectos en la salud se presentan a

UCUENCA

pocos minutos de ocurrida la exposición, e incluyen reducción del volumen espiratorio forzado en el primer segundo (VEF₁), el VEF₁ es la cantidad de aire que es exhalado de manera abrupta en el primer segundo después de una inhalación máxima, adicionalmente el SO₂ produce aumento de la resistencia de la vía aérea específica (factores que limitan el acceso del aire inspirado a los pulmones), y la aparición de síntomas como son disnea (ahogo o dificultad para respirar) y sibilancias (sonidos agudos similares a silbidos que se producen al respirar) (Rivero, 2019; J. Sánchez et al., 1999).

2.2.2.3 Monóxido de Carbono (CO).

Según (Téllez et al., 2006) *“El monóxido de carbono (CO) es un gas incoloro e inodoro que se forma por la combustión incompleta de material orgánico, en presencia deficitaria de oxígeno”.*

El CO una vez inhalado pasa al torrente sanguíneo formando Carboxihemoglobina, esto se da debido a que el CO tiene una mayor afinidad con la hemoglobina que el O₂, por lo que desplaza a este generando una disminución de transporte de oxígeno a los tejidos, generando hipoxia (Bolaños & Chacón, 2017).

2.2.2.4 Ozono (O₃).

El ozono (O₃) es un gas beneficioso en las capas más externas de la atmósfera porque es la primera protección ante los rayos UV provenientes del sol, pero se vuelve un gas perjudicial para el hombre a niveles troposféricos formando parte del smog, el tiempo de prevalencia del ozono en la atmósfera depende de la presencia y abundancia de sus precursores (Sánchez, 2006).

La exposición repetida a bajas dosis de ozono, como ocurre en días de alta contaminación, provoca un estado de estrés oxidativo crónico, adicionalmente este

ozono troposférico es muy irritativo de las vías aéreas, conjuntivas y pulmones (Bello et al., 2019).

2.3 La Temperatura Superficial.

Según Chen et al., (2022) la temperatura superficial es la temperatura radiante de la superficie terrestre, durante el día la Tierra absorbe el calor emitido por el Sol, sin embargo, esta situación cambia durante la noche, durante la noche la Tierra emite el calor previamente absorbido como radiación infrarroja. La creciente cobertura de edificios, superficies impermeables y actividades asociadas, incluido el transporte, han modificado drásticamente el ambiente térmico, la alteración de la superficie terrestre traerá cambios colaterales en el entorno atmosférico, lo que aumentará el riesgo de contaminación del aire y estrés por calor para los residentes urbanos.

2.4 Georeferenciación.

Hace referencia a una amplia gama de técnicas, cuya finalidad principal es la identificación de puntos geográficos, entendiéndose por puntos geográficos a un objeto o estructura que puede ser ubicado geográficamente (Hackeloeer et al., 2014).

Esta ubicación geográfica puede ser formal o informal, también conocido como absoluta y relativa, de este modo si se emplean coordenadas previamente definidas, el sistema de coordenadas será entonces denominado formal o absoluto, por ejemplo el sistema de coordenadas WGS84, su contraparte por tanto sería la informal o relativa, la cual se usa de manera más coloquial y consiste en usar un punto como origen o referencia para un posicionamiento más local, por ejemplo la Universidad se encuentra a tres cuadras del Banco Central (Hill, 2009).

2.5 Sistemas de Información Geográfica.

El trabajo de Dominguez, (2000) contiene una recopilación de conceptos referentes a los Sistemas de Información Geográfica, puesto que no se ha llegado a

UCUENCA

un consenso sobre su definición, de todos estos encontramos el de la “National Center for Geographic Information and Analysis (NCGIA) de los Estados Unidos (1990), un Sistema de Información Geográfica también conocido como SIG se puede definir como *“Un sistema de información compuesto por hardware, software y procedimientos para capturar, manejar, manipular, analizar, modelizar y representar datos georeferenciados, con el objetivo de resolver problemas de gestión y planificación”*.

Algunos de los componentes de los SIG son:

2.5.1 Mapas.

Es importante entender que un mapa es la representación de la realidad y la no realidad a la vez, esto se debe a que se debe representar una realidad tridimensional en bidimensional, para conseguir esto generalmente se representan las coordenadas “Latitud” y “Longitud” en el plano, mientras que a la “Altitud” se la representa como un atributo, otro factor que se debe considerar son las proyecciones, puesto que, estas sirven para representar la superficie esférica de la Tierra sobre un plano con la menor cantidad de deformaciones posible, y finalmente la escala, la cual es una relación existente entre una distancia horizontal del terreno (realidad) y su respectiva representación en el plano, la escala es un factor importante porque define el nivel de información obtenido (Dominguez, 2000; López et al., 2006).

2.5.2 Datos.

Según (Hackeloeer et al., 2014) un dato es una entidad que pueden definirse en múltiples dimensiones espaciales: 0-dimensional (puntos), unidimensional (líneas), bidimensional (áreas) y, rara vez, tridimensional (cuerpos).

2.5.3 *Análisis de Datos.*

Es una de las funciones básicas de un SIG y consiste en un grupo de procesos que pueden ser muy sencillo o muy complejos, que permiten modelar y analizar datos de origen muy variado, los SIG presentan la ventaja de una amplia gama de procesos en una sola herramienta, lo que permite la generación de nueva información que de otro modo no sería posible (Olaya, 2014).

2.6 Teledetección.

Los sensores remotos o la teledetección es la ciencia encargada de obtener información de un objeto, un área o un fenómeno ubicado sobre la superficie terrestre. Adicionalmente la teledetección, no hace referencia solo a la captación de datos sino también a su posterior tratamiento y análisis. El término teledetección es una adaptación del vocablo Remote Sensing que hace referencia a una percepción remota. Esta definición es importante porque nos brinda un dato fundamental sobre los sensores remotos, el cual es que el instrumento no se encuentra en contacto físico o directo con el objeto, lo cual nos puede permitir obtener datos rápidos, económicos, globales, actualizados, precisos y flexibles (Pérez & Muñoz, 2006).

2.7 Google Earth Engine (GEE).

Google Earth Engine es una herramienta que innova día a día, permite desarrollar análisis espaciales a nivel global utilizando datos de la nube de información que se encuentra disponible en materia de información de imágenes satelitales, dicho programa lo realiza utilizando procesamiento de datos, con esta innovación se soluciona en algo lo que se llama el rezago tecnológico del procesamiento de grandes bases de datos de imágenes satelitales (Perilla & Mas, 2020).

2.7.1 Descripción General de GEE.

La estructura general de GEE está dispuesta por cuatro elementos indispensables que son:

El primero es la infraestructura de Google, en donde se puede disponer de los servidores los mismos que ayudan a realizar el análisis al mismo tiempo para agilizar el procesamiento. El segundo elemento es el acervo de datos (datasets), hace referencia al grupo de sensores donde se almacena la información como por ejemplo Sentinel, Landsat, etc. En donde se crean enormes bases de datos los mismos que pueden ser consultados por diferentes criterios, por ejemplo, fecha, hora, etc. El tercer elemento es la API (Application Program Interface) la cual consiste en comandos y funciones en lenguaje JAVA los mismos que son inmodificables y no se puede acceder al código lo que le hace a este elemento bastante restrictivo. El cuarto elemento es el Code Editor, es un entorno de desarrollo online, en donde el usuario hace uso de los códigos de trabajo (scripts), llamar a los datos procesarlos y visualizarlos de manera digital (Perilla & Mas, 2020).

2.7.2 Catálogo de Datos Sentinel-5P.

El satélite Sentinel 5 Precursor o Sentinel 5P fue puesto en órbita el 13 de octubre de 2017, formando parte del Programa Europeo de Observación de la tierra “Copernicus” (Zheng et al., 2019).

El satélite Sentinel 5P emplea el sensor pasivo TROPOMI (TROPOspheric Monitoring Instrument), el cual es un espectrómetro cuyas bandas espectrales cubren los ultravioleta (UV), visibles (VIS) de 270 a 500 nm, infrarrojo cercano (NIR) de 675 a 775 nm, e infrarrojo de onda corta (SWIR) de 2305 a 2385 nm. Estas bandas fueron seleccionadas para optimizar la observación de componentes atmosféricos claves, entre los cuales se incluyen dióxido de nitrógeno (NO₂), dióxido de azufre (SO₂),


UCUENCA

monóxido de carbono (CO), ozono (O₃), metano (CH₄), formaldehído (CH₂O), aerosoles y nubes (ESA, 2017; Veeffkind et al., 2012).

2.7.3 TROPOMI.

El sensor TROPOMI es un espectrómetro de visualización de imágenes del NADIR (perpendiculares al suelo), integrados en el satélite Sentinel 5P, el cual es un satélite de órbita síncrona solar casi polar que vuela a una altitud de 817 km, TROPOMI opera en una configuración de escoba de empuje sin escaneo, con un campo de visión instantáneo de 108° y un período de medición de aproximadamente 1 segundo, con un tiempo local del nodo ascendente a las 13:30 horas. Esto da como resultado un ancho de franja de aprox. 2600 km, una resolución a lo largo de la pista de 7 km y cobertura global diaria, como se puede apreciar en la figura 1 (ESA, 2017; lalongo et al., 2019).

Figura 1: TROPOMI




Fuente: Agencia Espacial Europea.

3 MATERIALES Y MÉTODOS.

3.1 Descripción de la Zona de Estudio.

Como se muestra en la Figura 2, el Ecuador continental se encuentra ubicado en la parte noreste de América del Sur, limitando al norte con Colombia, al sur y al este con Perú, y al oeste con el Océano Pacífico. Con una extensión de 283,561 km². El Ecuador se encuentra dividido por la línea ecuatorial, debido a esto se encuentra en ambos hemisferios. Las principales unidades de relieve son la llanura al norte del Golfo de Guayaquil que va desde los 1 m hasta los 1000 m donde se ubican las estribaciones orientales de los Andes, la sección de la Cordillera de los Andes en el centro del país de manera longitudinal se eleva desde los 1000 m hasta los 6300 m con el Chimborazo como punto más alto del Ecuador y por último un extenso sector de la llanura amazónica ubicada al oriente del país que se extiende desde las estribaciones orientales de la cordillera de los Andes y se divide en alta Amazonía cuando es mayor a 1000 m y baja Amazonía menor a 1000 m, en su totalidad el país alberga una gran cantidad de habitantes teniendo una población de más de 17 millones y una temperatura que varía de región a región de entre 4 °C en el páramo a 30 °C en las regiones costa o el oriente, que da un promedio a nivel país de 23 a 25 °C, temperaturas agradables y que podrían variar drásticamente por el cambio climático que se presenta en la actualidad no solo en el Ecuador sino a nivel mundial (Aguirre et al., 2010; Ludeña & Wilk, 2013; Villavicencio, 1858).

Figura 2: Zona de Estudio.



Fuente: Elaboración propia.

3.2 Metodología General.

3.2.1 Programas Utilizados.

La Tabla 1 presenta un breve resumen de los programas o plataformas a usar en el estudio.

Tabla 1: Programas a utilizarse en el desarrollo de la investigación.


Programa o Plataforma	Actividad
Google Earth Engine.	Intermediario entre el usuario y la información satelital.
ArcGIS 10.5.	Exportación de los valores de los ráster de las imágenes satelitales.
R-Studio 1.4.1106.	Manipulación de datos y correlaciones.
Excel 2019.	Organización de Datos.

Fuente: Elaboración propia.

3.2.2 Metodología General.

A continuación, en la Figura 3 se presentará la metodología general del procedimiento llevado a cabo en el presente estudio:

Figura 3: Metodología General.



Fuente: Elaboración propia.

3.3 Obtención de datos de Temperatura.

Los datos de temperatura fueron obtenidos del Instituto Nacional de Meteorología e Hidrología (INAMHI) y fueron analizados en excel, esta información nos fue entregada de manera diaria desde el 1 de enero de 2019 al 31 de diciembre de 2019, y antes de su uso se realizó un control de calidad y posteriormente el análisis de vacíos, en el cual si una estación tenía un porcentaje de valores faltantes o vacíos mayores al 10 % se procedía a descartar dicha estación.

Se considera como un valor faltante a aquel que no consta en el registro debido a cualquier eventualidad que pudo haberse presentado, un valor de % VF (Valores Faltantes) superior al 10 % se considera inaceptable, según varios autores, tales como; Dagnino, (2014), por otra parte, autores como Acuña & Rodríguez, (2004), consideran que datos faltantes entre 1-5 % son manejables, del 5-15 % son utilizables, pero requieren de complejos de imputación, y datos por encima del 15 % son datos inutilizables.

Para el análisis de vacíos se contabilizaron los datos presentados, y se restaron de 365 datos totales por estación, con ese valor resultante se calculó el porcentaje de vacíos en función de:

$$\% VF = \frac{\# \text{ De datos vacíos}}{365} * 100$$

*Ecuación 1: Porcentaje de Valores Faltantes.
Fuente: Acuña & Rodríguez, (2004).*

Se inicio con el relleno de datos faltantes, con el cálculo promedio mensual, a este método se lo conoce como imputación por sustitución de media aritmética (Hadeed et al., 2020), para finalmente calcular la temperatura promedio mensual y anual, para posteriormente exportar esta información en un archivo con formato csv (texto delimitado por comas).

3.3.1 *Obtención de imágenes Interpoladas.*

Cada estación meteorológica contaba con coordenadas y datos de temperatura de ese punto, siendo así datos puntuales, dado que nuestra área de estudio abarca todo el país, es necesario realizar interpolaciones de estos datos con la finalidad de poder encontrar relaciones entre las concentraciones de los diferentes gases de efecto invernadero y la temperatura superficial.

Para la interpolación se utilizaron las coordenadas de cada una de las estaciones del INAMHI que pasaron el control de calidad y se aplicaron las técnicas de interpolación de Vecino más Próximo (IDW) y Kriging Simple. La interpolación se la realizó por medio del software de información geográfica ArcGis Versión 10.5.

3.3.1.1 **Vecino Más Próximo (IDW).**

El método de ponderación de distancia inversa (IDW) también conocido como Vecino Más Próximo, es un modelo de interpolación espacial determinista, de manera general este método determina valores desconocidos mediante la distancia promedio de los valores de los puntos de datos de muestra en la vecindad de cada celda, puesto que la premisa general de este método es que los valores de los atributos de cualquier par de puntos están relacionados entre sí, pero su similitud está inversamente relacionada con la distancia entre las dos ubicaciones, la superficie a interpolar debe ser de una variable dependiente de la ubicación (Lu & Wong, 2008). IDW asume que cada punto de medición tiene un efecto local que disminuye con la distancia, se asigna más peso a los puntos más cercanos a la posición prevista que a los puntos más lejanos (Toro & Melo, 2009).

La técnica de interpolación IDW (Inverse Distance Weighted) indica que las cosas que están cerca entre sí son más parecidas que las que están más alejadas.

UCUENCA

Para interpolar (predecir) un valor en cualquier zona que no presente una medición, el método utilizará los valores medidos que rodean la ubicación de predicción. Los valores que se encuentran más cercanos a la ubicación de la predicción tendrán más influencia en el valor predicho que los valores que están más lejos. Por tal razón, el método IDW asume que cada punto medido tiene una influencia de ubicación que disminuye con la distancia. La ecuación general para el método de IDW es:

$$\hat{Z}(S_o) = \sum_{i=0}^n \gamma_i Z(S_i)$$

*Ecuación 2: IDW.
Fuente: Boucher, R., & Wu, J. (2009).*

En donde $\hat{Z}(S_o)$ es el valor que se desea predecir, n es el número de puntos medidos que rodean la ubicación, γ_i son los pesos asignados a cada punto medido que vamos a utilizar (Boucher, R., & Wu, J, 2009).

3.3.1.2 Kriging Simple.

Es un procesamiento de datos geo-estadísticos para generar una estimación de una superficie de un conjunto de puntos que contienen datos con valores en z . La peculiaridad de este método de interpolación es que para que sea efectivo su uso se debe realizar una investigación interactiva del fenómeno dado que contiene valores en z .

La técnica de interpolación de Kriging mide el grado de dependencia espacial entre 2 puntos conocidos en términos de semivariancia, la cual viene dada por:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^n [z(x_i) - z(x_i + h)]^2$$

*Ecuación 3: Kriging Simple.
Fuente: Boucher, R., & Wu, J. (2009).*

En donde h es la distancia entre puntos conocidos denominada desfase; n es el número de pares de puntos conocidos separados por h ; y z es el valor del atributo en la ubicación x_i o $x_i + h$. Se espera que la semivarianza aumente a medida que aumenta h . En pocas palabras se podría decir que este método de interpolación está planteado de manera que nos dé el mejor estimador lineal no sesgado con una varianza mínima (Boucher, R., & Wu, J, 2009).

3.3.2 Análisis de las imágenes de la Temperatura.

3.3.2.1 Error Absoluto Medio (MAE).

Es un promedio de los errores absolutos, usa la escala de las series de datos, por consiguiente, no se pueden evaluar datos entre diferentes escalas, y es una medida común sobre el error de predicción que sirve para cuantificar la precisión de una técnica de predicción (Pindyck & Rubinfeld, 2001).

$$MAE = \frac{\sum_{i=1}^N |X - \varphi|}{N}$$

*Ecuación 4: Error Absoluto Medio.
Fuente: Pindyck & Rubinfeld, (2001).*

Donde X son los valores de los datos observados, φ son los valores estimados o pronosticados y N es el número de datos.

3.3.2.2 Raíz de la Desviación Cuadrática Media (RMSE).

Mide la cantidad de error entre los datos observados y los datos predichos, el RMSE cuantifica cuán diferente es un conjunto de valores. Cuanto más pequeño es un valor RMSE, más cercanos son los valores predichos y observados (Pindyck & Rubinfeld, 2001).

$$RMSD = \sqrt{\frac{\sum_{i=1}^N (X - \varphi)^2}{N}}$$

*Ecuación 5: Raíz de la Desviación Cuadrática Media.
Fuente: Pindyck & Rubinfeld, (2001).*

Donde X son los valores de los datos observados, φ son los valores estimados o pronosticados y N es el número de datos.

3.3.2.3 Error Porcentual Medio Absoluto (MAPE).

Mide el tamaño del error (absoluto) en términos porcentuales, lo cual permite su fácil interpretación, también es conocido como Porcentaje de Error Medio Absoluto (PEMA) o (EPAM) (Pindyck & Rubinfeld, 2001).

$$MAPE = \frac{\sum_{i=1}^N 100 \frac{|X - \varphi|}{X}}{N}$$

*Ecuación 6: Error Porcentual Medio Absoluto.
Fuente: Pindyck & Rubinfeld, (2001).*

Donde x son los valores de los datos observados, φ son los valores estimados o pronosticados y N es el número de datos.

3.3.2.4 Criterio de Información de Akaike (AIC)

En 1973, Akaike encontró una relación entre la máxima verosimilitud (análisis estadístico) y la divergencia de Kullback-Leibler (teoría de la información) y, con base en ello, definió un criterio de selección de modelo, ahora denominado Criterio de Información de Akaike (AIC) (Portet, 2020). El AIC es un método de comparación de modelos ampliamente usado debido a que considera tanto la bondad del ajuste como los parámetros a utilizarse (Lee, 2013). Para modelos con el mismo número de parámetros ajustables, selecciona el modelo con el mejor ajuste por mínimos cuadrados. Los modelos con más parámetros normalmente se ajustan mejor, pero la

adición de más parámetros puede no ser estadísticamente justificable, el de mejor ajuste será aquel cuyo valor de AIC sea menor (Ingdal et al., 2019).

$$AIC = 2 \left(\frac{k}{n} \right) + \ln \left(\frac{SSe}{n} \right)$$

Ecuación 7: Criterio de Información de Akaike.

Fuente: Ingdal et al., (2019).

En donde k representa al número de parámetros, n el número de observaciones, y SSe representa a la suma de los errores al cuadrado.

3.4 Metodología de obtención de datos de TROPOMI Sentinel-5P.

La plataforma Google Earth Engine es una plataforma donde se almacenan cientos de miles de imágenes satelitales de alcance global, el mismo que sirve para realizar análisis de las ciencias de la tierra y es gratuito para uso académico y de investigación. Su uso es variado y va desde detectar cambios en la superficie terrestre hasta cuantificar dichos cambios (Gorelick et al., 2017).

3.4.1 Obtención de imágenes satelitales TROPOMI Sentinel-5P.

Para la obtención de las imágenes satelitales se utilizó la plataforma GEE, mediante el link <http://www.code.earthengine.google.com>, este entorno como se ha mencionado antes, contiene un amplio catálogo de imágenes satélites de alcance global.

El Sentinel 5P fue lanzado el 13 de octubre de 2017, sin embargo, estos datos no estuvieron disponibles hasta meses después. En la Tabla 2 se presentan las fechas de liberación de datos usados en proyecto según la propia Agencia Espacial Europea (ESA).

Tabla 2: Disponibilidad de imágenes.

Gas.	Disponibilidad.
Monóxido de Carbono.	10 de julio de 2018.
Dióxido de Nitrógeno.	10 de julio de 2018.
Ozono.	17 de octubre de 2018.
Dióxido de Azufre.	17 de octubre de 2018.

Fuente: Elaboración propia.

Para la obtención de la información satelital en la plataforma Google Earth Engine, se utilizaron los scripts presentados en el Anexo 2.

Las imágenes obtenidas de GEE, se descargaron en formato tiff con el sistema de coordenadas geográficas WGS84, adicionalmente dichas imágenes abarcaron un área mayor a la necesaria, por consiguiente, se procedió a realizar una re proyección de imágenes, esto permitió cambiar el sistema de coordenadas WGS84 de geográficas a planas, estableciéndose en WGS84 UTM Zona 17S.

En cuanto al área necesaria, al ser información tipo ráster se empleó la extracción por máscara, estableciendo como la máscara al perfil del Ecuador, información obtenida del INEC.

Finalmente, las imágenes aún conservaban sus unidades iniciales (mol/m^2), para una mayor facilidad de comprensión y análisis de datos se procedió a realizar una conversión de unidades a $\mu\text{mol}/\text{m}^2$.

Las imágenes generadas anteriormente tuvieron que ser re ensamblaron para su uso en RStudio, para ello se empleó el método de interpolación bilineal. Este método de interpolación será usado únicamente para el reensamblaje de las imágenes, puesto que, para poder utilizar la correlación entre dos imágenes, estas deben poseer las mismas características, tales como: número de filas, número de columnas y tamaño de píxel.

La interpolación bilineal reduce en gran medida el error de interpolación, puesto que consiste en utilizar cuatro celdas vecinas más próximas, el resultado final de cada celda consiste en el valor promedio ponderado considerando la distancia de cada píxel (Barreto, 2009).

Para la aplicación del método bilineal, se utilizó a las imágenes de temperatura calculadas con el método IDW como base, puesto que estas ya poseían características similares entre ellas, una vez utilizada las imágenes de temperatura como base las imágenes de los gases se adecuaron a esas características.

3.5 Relación entre la temperatura superficial del aire y la columna de GEI.

Para conocer la relación entre la temperatura y los gases GEI se decidió aplicar modelos de regresión con el fin de determinar la influencia de los GEI en la temperatura local.

3.5.1 Regresión Simple.

La regresión lineal es un método estadístico el cual estudia la relación lineal que podría o no existir entre dos variables, para hacer posible este estudio es necesario disponer de datos que permitan la cuantificación de dicha relación, a la variable dependiente o respuesta se le identifica como “Y” y a la variable predictora o independiente como “X” (Prion & Haerling, 2020).

El modelo de regresión lineal simple se describe de acuerdo a la ecuación:

$$Y = \beta_0 + \beta_1 X_1 + \epsilon$$

*Ecuación 8: Regresión Lineal Simple.
Fuente: Prion & Haerling, (2020).*

β_0 : la ordenada en el origen, β_1 : la pendiente y ϵ : el error aleatorio

3.5.2 Regresión Lineal Múltiple

Se considera a la Regresión Lineal Múltiple una extensión de la regresión lineal simple, es decir la regresión lineal múltiple permite generar un modelo lineal en el que el valor de la variable dependiente o respuesta (Y) se determina a partir de un conjunto de variables independientes llamadas predictores (X_1, X_2, X_3, \dots) (Etemadi & Khashei, 2021).

$$Y_i = (\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_n X_{ni}) + e_i$$

*Ecuación 9: Regresión Lineal Múltiple.
Fuente: Etemadi & Khashei, (2021).*

β_0 : es la ordenada en el origen, el valor de la variable dependiente

Y cuando todos los predictores son cero.

β_i : es el efecto promedio que tiene el incremento en una unidad de la variable predictiva

X_i sobre la variable dependiente

Y, manteniéndose constantes el resto de variables. Se conocen como coeficientes parciales de regresión

e_i : es el residuo o error, la diferencia entre el valor observado y el estimado por el modelo.

3.5.3 Coeficiente de Determinación R^2

Hace referencia a una medida entre los datos y la línea de regresión ajustada, cuando se habla de regresión lineal ajustada se lo denomina coeficiente de determinación múltiple (Cheng et al., 2014).

$$R^2 = \frac{\text{Variación Explicada}}{\text{Variación Total}}$$

*Ecuación 10: Coeficiente de Determinación R^2 .
Fuente: Cheng et al., (2014).*

UCUENCA

Los valores reflejados siempre estarán entre 0 y 1 siendo 0; el modelo no explica ninguna porción de la variabilidad de los datos y 1; explica toda la variabilidad de datos.


4 RESULTADOS Y DISCUSIÓN

4.1 RESULTADOS

4.1.1 *Depuración de Datos*

Se trabajaron con 365 datos por estación que corresponden a los 365 días del año, los datos obtenidos del INAMHI fueron 98 los cuales después de un control de calidad quedaron un total de 88 estaciones presentadas en la Figura 4, el control de calidad consistió en retirar los datos incongruentes y duplicados, de las 88 estaciones después de la depuración de datos (Tabla 3) quedaron 56 estaciones con las cuales se trabajó, las ubicaciones de las mismas se presentan en la Figura 5.

Figura 4: Estaciones INAMHI primer filtro.



Fuente: *Elaboración propia*

Tabla 3: Porcentaje de Vacíos

ESTACION	N° VACÍOS	% VACÍOS	ESTACION	N° VACÍOS	% VACÍOS
M0001	0,00	0,00	M1242	214,00	58,63
M0002	0,00	0,00	M1246	1,00	0,27
M0003	4,00	1,10	M1247	11,00	3,01
M0004	0,00	0,00	M1249	355,00	97,26
M0006	0,00	0,00	M1253	0,00	0,00
M0007	139,00	38,08	M1256	301,00	82,47
M0008	0,00	0,00	M1259	280,00	76,71
M0012	117,00	32,05	M1259_1	0,00	0,00
M0024	17,00	4,66	M1271	0,00	0,00
M0025	0,00	0,00	M1273	185,00	50,68
M0026	0,00	0,00	M1274	0,00	0,00
M0031	0,00	0,00	M5025	121,00	33,15
M0033	0,00	0,00	M5026	119,00	32,60
M0037	1,00	0,27	M5027	117,00	32,05
M0055	0,00	0,00	M5028	253,00	69,32
M0102	0,00	0,00	M5029	314,00	86,03
M0103	0,00	0,00	M5030	249,00	68,22
M0105	0,00	0,00	M5031	287,00	78,63
M0117	109,00	29,86	M5035	2,00	0,55
M0124	2,00	0,55	M5036	2,00	0,55
M0146	0,00	0,00	M5037	6,00	1,64
M0150	0,00	0,00	M5038	7,00	1,92
M0156	0,00	0,00	M5039	7,00	1,92
M0162	0,00	0,00	M5040	6,00	1,64
M0168	177,00	48,49	M5041	3,00	0,82
M0188	0,00	0,00	M5042	3,00	0,82
M0203	351,00	96,16	M5089	0,00	0,00
M0221	75,00	20,55	M5090	1,00	0,27
M0258	0,00	0,00	M5092	127,00	34,79
M0673	100,00	27,40	M5103	132,00	36,16
M0712	41,00	11,23	M5124	0,00	0,00
M1036	0,00	0,00	M5125	73,00	20,00
M1040	0,00	0,00	M5126	50,00	13,70
M1094	0,00	0,00	M5131	17,00	4,66
M1107	0,00	0,00	M5132	0,00	0,00
M1124	0,00	0,00	M5133	0,00	0,00
M1170	0,00	0,00	M5134	65,00	17,81
M1203	62,00	16,99	M5135	5,00	1,37
M1207	0,00	0,00	M5138	116,00	31,78


UCUENCA

M1208	0,00	0,00	M5139	97,00	26,58
M1217	0,00	0,00	M5147	43,00	11,78
M1219	0,00	0,00	M5148	166,00	45,48
M1233	0,00	0,00	M5149	271,00	74,25
M1240	0,00	0,00	M5150	117,00	32,05

Fuente: Elaboración propia

Teóricamente se propuso trabajar con un 10 % de vacíos, sin embargo, al momento de realizar la parte práctica se pudo apreciar que ninguna de las estaciones trabajadas superó el 5 %, siendo la estación con mayor porcentaje de vacíos la M5131 con un porcentaje de 4,66 %, ubicada en Guayaquil. Motivo por el cual las estaciones M0712, M5126 y M5147, no fueron consideradas como utilizables a pesar de tener porcentajes inferiores a 15 %, que según algunos autores aún pueden ser útiles, siendo estos de 11,23 %, 13,70 % y 11,78 % respectivamente.

Figura 5: Estaciones INAMHI.



Fuente: Elaboración propia.


4.1.2 *Datos de Temperatura.*

4.1.2.1 **Datos Mensuales de Temperatura.**

La Figura 6 presenta las temperaturas promedio obtenidas mediante la técnica de interpolación del vecino más próximo o por sus siglas en inglés (IDW). Para entender la siguiente figura se debe considerar que A representa al mes de enero, B a febrero, C a marzo, D a abril, E a mayo, F a junio, G a julio, H a agosto, I a septiembre, J a octubre, K a noviembre, y finalmente L a diciembre.


Se puede apreciar también en la Figura 5 que la mayor concentración de temperatura se encuentra la zona Costera, sin embargo, hay que tener en cuenta que esta información también se puede considerar como sesgada debido a la falta de datos en la zona de la Amazonía.

Figura 6: Temperatura Promedio Mensual: IDW.



Fuente: Elaboración Propia.

Figura 7: Temperatura Promedio Mensual: IDW.



Fuente: Elaboración Propia.


En la Figura 7 podemos notar que los datos tienen una distribución asimétrica negativa con lo que indica que la mayor parte de los datos se encuentran dispersos por debajo de la media, esto tiene sentido al considerar que en la Figura 5 se presentó que la mayor parte de la temperatura más alta se encuentra las personas en la zona de la Costa, mientras que en la zona de la Sierra y en la zona de la Amazonía se encontraban temperaturas más bajas.

UCUENCA

En la Figura 8 se presentan las temperaturas promedio obtenidas mediante la técnica de interpolación Kriging Simple, la distribución de los meses es similar a la presentada en la Figura 6.


Al comparar el la Figura 8 con la Figura 6 se puede ver que el método Kriging Simple propone que la temperatura de la Amazonía es mayor a comparación de la temperatura propuesta por el método IDW, la Figura 8 al igual que la Figura 6 presentan una línea divisoria que funciona como barrera entre la Costa y la Sierra ecuatoriana, esta barrera haría referencia a la Cordillera Occidental de la Cordillera de los Andes.

Figura 8: Temperatura Promedio Mensual: Kriging Simple.



Fuente: Elaboración Propia.

Figura 9: Temperatura Promedio Mensual: Kriging Simple.




Fuente: Elaboración Propia.

La Figura 9 al igual que la Figura 7, tiende a una asimetría negativa, por otra parte, la mediana de los primeros 6 meses en la Figura 9 están ligeramente más al centro que los de la Figura 7, a la vez que el espacio intercuartílico de esos meses es mayor que los dados por IDW.

4.1.2.2 Datos Anuales de Temperatura

Figura 10: Temperatura Promedio Anual.



Fuente: Elaboración Propia.

En la Figura 10 tendremos una comparación entre ambos métodos con respecto a las concentraciones anuales, en cuanto a temperatura máxima, la temperatura presentada por el método IDW es ligeramente mayor que la de Kriging Simple, al mismo tiempo que manifiesta que su temperatura mínima es menor que la de Kriging. El método Kriging Simple declara que la temperatura de la Amazonía es mayor que la del método IDW que focaliza esta temperatura mayor en 3 puntos.

4.1.3 Selección de Datos Interpolados.

La Tabla 4 presenta el resumen de los resultados con respecto a los errores calculados, el coeficiente de determinación R^2 y el Criterio de Información de Akaike (IAC), esta misma tabla indica que el método IDW tuvo un mejor ajuste con respecto a los valores obtenidos de las estaciones que el Kriging Simple en cuanto a errores.

El coeficiente R^2 es similar en ambos, teniendo una ligera variación en el cuarto decimal, marcando al método IDW como ligeramente mejor ajustado que Kriging Simple, por otra parte, el valor de AIC de Kriging Simple es menor lo que indicaría una mejor verosimilitud en los datos, aunque esta ligera variación se presenta a partir del tercer decimal.

Por tanto, al ser los valores de R^2 y AIC muy parecidos nos enfocaremos en los errores, a pesar de que ambos tienen valores de error bajos, las imágenes obtenidas con el método IDW serán las que se utilizarán en la segunda fase del proyecto, al tener valores de errores inferiores al Kriging Simple.

Tabla 4: Coeficientes.

	MAE	RMSD	MAPE	R^2	AIC
IDW	0,02	0,20	0,15	0,9933	1,783
KRIGING SIMPLE	0,12	0,53	0,89	0,9932	1,781


Fuente: Elaboración Propia.

4.1.4 Datos satelitales TROPOMI Sentinel-5P.

4.1.4.1 Concentraciones Mensuales de los diferentes gases de efecto invernadero.

Para poder entender las figuras que se presentan en esta pequeña sección hay que considerar que A representa al mes de enero, B a febrero, C a marzo, D a abril, E a mayo, F a junio, G a julio, H a agosto, I a septiembre, J a octubre, K a noviembre, y finalmente L a diciembre.


Figura 11: Concentraciones Mensuales de CO.



Fuente: Elaboración propia.

En la Figura 11 se presentan las concentraciones mensuales promedio de CO, en estas figuras se puede apreciar que la Figura 7C es el que visualiza la concentración máxima más alta, en contra posición de F que presenta la concentración máxima más baja. También se puede ver que las concentraciones más altas se encuentran en las zonas costera y amazónica, mientras que las concentraciones más bajas se encuentran ubicadas en la Sierra, presentando una clara división regional, al mismo tiempo se pueden ver dos barreras que acentúan esta división, siendo la una la Cordillera Occidental, la cual separa la Costa y la Sierra, y la otra la Cordillera Oriental, la cual dividiría a la Sierra y la Amazonía.


Figura 12: Concentraciones Mensuales de CO.



Fuente: Elaboración propia.

Las concentraciones presentadas en la Figura 12, muestran una asimetría positiva, a la vez que su dispersión de los datos es principalmente por debajo de la mediana como lo muestran los bigotes, también se puede notar que su valor es variante a lo largo del año presentando el mejor ajuste en el mes de marzo.

Figura 13: Concentraciones Mensuales de O₃.

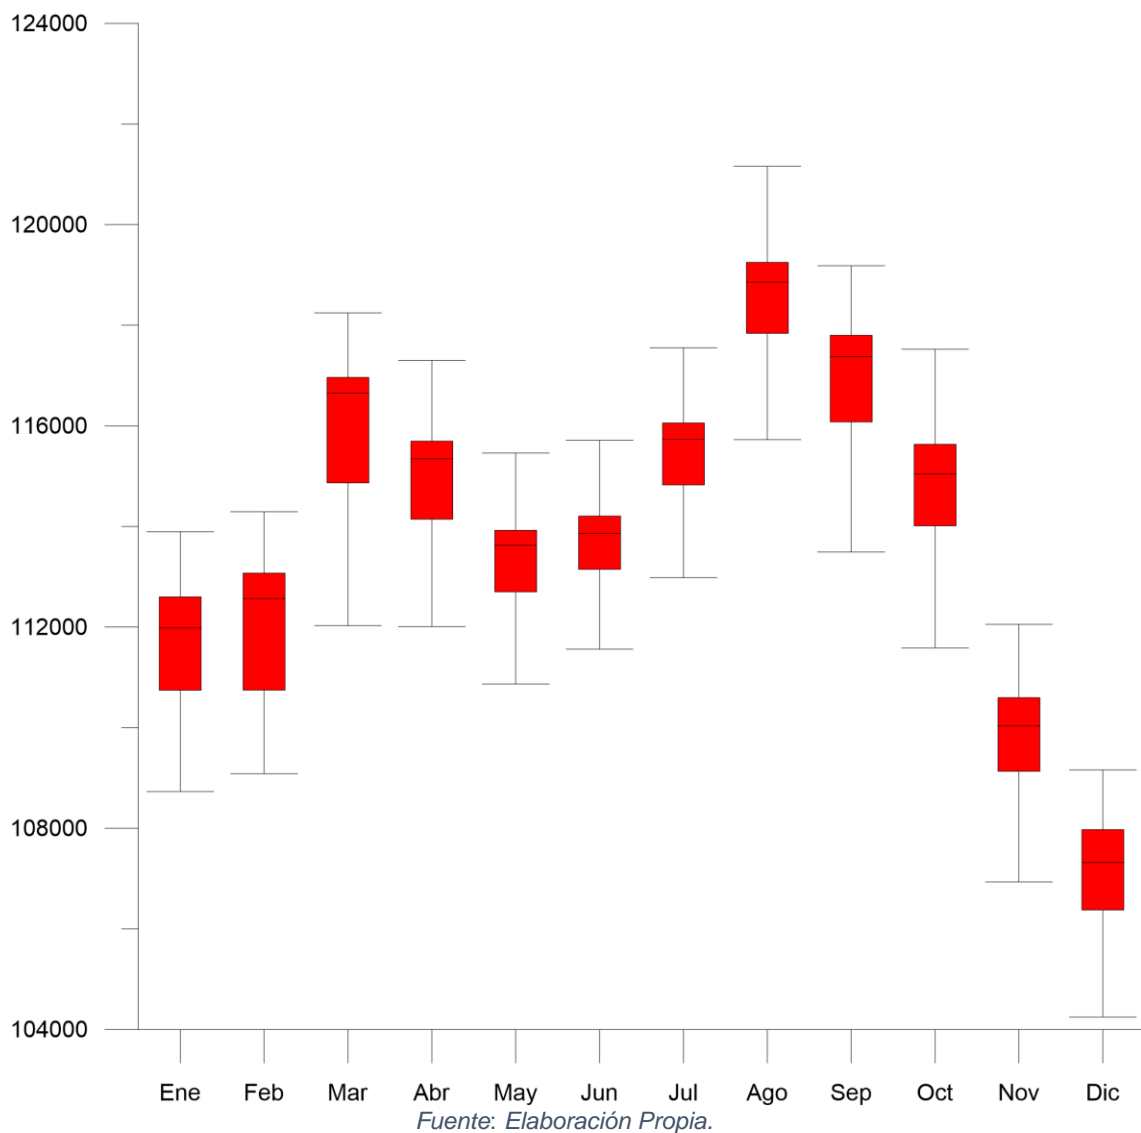


Fuente: Elaboración propia.

UCUENCA

La Figura 13 presenta las concentraciones mensuales promedio de O_3 , en estas figuras se puede apreciar que H es el mes con la concentración máxima más alta, en contra posición de L que presenta la concentración máxima más baja. El O_3 al igual que el CO muestra que las concentraciones más altas se encuentran en las zonas Costera y Amazónica, mientras que las concentraciones más bajas se encuentran ubicadas en la Sierra, a la vez que se muestra una clara regionalización del país. Otro dato a destacar es que en las Zonas de las Cordilleras se presenta nuevamente una barrera con concentraciones medias. Las concentraciones no se encuentran focalizadas en un solo punto, sino que se encuentran dispersos por una región específica.


Figura 14: Concentraciones Mensuales de O₃.



La Figura 14 muestra una tendencia asimétrica positiva, con los bigotes superiores más cortos a comparación de los bigotes inferiores, lo cual indicaría que la dispersión de los puntos se encuentra principalmente en la zona por debajo de la mediana.

También se puede notar que las concentraciones no son constantes, sino que varían a lo largo del año, y con concordancia con la Figura 13, la concentración más alta se encuentra durante el mes de agosto, y de igual modo en ambas se muestra que el valor de concentración más baja se encuentra en el mes de diciembre.

Figura 15: Concentraciones Mensuales de SO₂ (Con Concentraciones Negativas).



Fuente: Elaboración Propia.


UCUENCA

En la Figura 15 se puede apreciar una clara falta de datos en la zona alta de la Cordillera tanto Occidental como Oriental, según la información de la misma ESA esto se debe al ruido de los datos o a una concentración muy baja de los mismos, y según han declarado no es necesario el relleno de los datos faltantes salvo el caso en que la información presente incongruencias. A pesar de que en la leyenda se presentan concentraciones máximas, en las figuras individuales estas concentraciones son muy escasas, manteniéndose principalmente en sus concentraciones medias.

El SO_2 , presentan falta de datos, por otra parte, los datos empleados en esta tesis son los OFFL, u offline, los cuales se distribuyen a los usuarios después de 5 días de tomados los datos, a diferencia de los NRT, Near Real Time, los cuales están disponibles 3 horas después de su toma, todos los gases a excepción del CH_4 tiene disponibles ambas versiones. En esta tesis se utiliza la plataforma de Google Earth Engine, empleando datos de nivel 2, y según la misma plataforma:

“Los activos OFFL contienen datos de una sola órbita (que, debido a que la mitad de la Tierra está oscura, solo contiene datos de un solo hemisferio). Debido al ruido de los datos, a menudo se observan valores negativos de la columna vertical, en particular sobre regiones limpias o para bajas emisiones de SO_2 . Se recomienda no filtrar estos valores salvo en el caso de los valores atípicos, es decir, para las columnas verticales inferiores a $-0,001 \text{ mol/m}^2$ ” (Copernicus Sentinel-5P (procesado por ESA), 2020).


Figura 16: Concentraciones Mensuales de SO₂ (Con Concentraciones Negativas).



Fuente: Elaboración Propia.

La Figura 16 presentan información mejor ajustada con respecto a su asimetría, a lo largo del año las concentraciones muestran un comportamiento estable, sin variaciones extremas, en cuanto a sus bigotes, estos no muestran grandes diferencias entre sí, y del mismo modo no hay presencia de datos atípicos.

Figura 17: Concentraciones Mensuales de SO₂ (Sin Concentraciones Negativas).




Fuente: Elaboración Propia.

UCUENCA

La Figura 17 presenta las concentraciones del SO_2 , en el cual se consideró a las concentraciones negativas mostradas en la Figura 15 como cero, dado que, se buscó determinar si la afirmación de la ESA con respecto a los valores negativos era válida.

Los datos presentan las mismas concentraciones máximas, puesto que la variación se realizó en las concentraciones mínimas, predominando las mismas sobre la superficie ecuatorial, especialmente en la zona Amazónica. Al mismo tiempo, las concentraciones del gas se encuentran dispersas y no focalizadas, lo que genera que en este caso en particular no exista una regionalización.


Figura 18: Concentraciones Mensuales de SO₂ (Sin Concentraciones Negativas).



Fuente: Elaboración Propia.

Dado que la Figura 18 es el boxplot de la Figura 17 en el cual se consideró al cero como la concentración mínima eliminando cualquier valor por debajo de esta, la Figura 18 presenta la particularidad de presentar datos principalmente de cero, la asimetría no puede ser determinada debido a que la mayor parte de los datos estudiados son cero, que indicaría una baja concentración del mismo.

Figura 19: Concentraciones Mensuales de NO₂ Troposférico (Con Concentraciones Negativas).




Fuente: Elaboración Propia.

En la Figura 19 se presenta las concentraciones mensuales promedio de NO₂ Troposférico, en estas figuras se puede apreciar que la Figura 19B es el mes con la concentración máxima más alta, en contra posición de la Figura 19C que presenta la concentración máxima más baja. El NO₂ Troposférico al igual que el SO₂ presenta

UCUENCA

vacíos de información en la Zona de la Cordillera, adicionalmente de vacíos en la zona costera, siendo la Región Amazónica la mejor demarcada, las concentraciones máximas se pueden encontrar principalmente en la Zona de la Costa, específicamente en el área de Guayas.


Figura 20: Concentraciones Mensuales de NO₂ Troposférico (Con Concentraciones Negativas).



Fuente: Elaboración Propia.

La Figura 20 muestra que el NO₂ presenta principalmente una asimetría negativa, también presenta a los meses de agosto y septiembre como los meses con mayor distancia intercuartílica, a la vez que, septiembre presenta la mayor distribución de puntos.

Figura 21: Concentraciones Mensuales de NO₂ Troposférico (Sin Concentraciones Negativas).




Fuente: Elaboración Propia.

UCUENCA

En la Figura 21, los resultados negativos fueron reemplazados por una concentración de cero, en esta figura las concentraciones mínimas predominan en la zona Amazónica, con la excepción de los meses A, C y H. Al igual que su homónimo anterior, existen datos perdidos en las zonas de las cordilleras, la concentración máxima predomina en la zona del Guayas. A la vez, que el resto de la Costa, se encuentra a lo largo del año con concentraciones medias.


Figura 22: Concentraciones Mensuales de NO₂ Troposférico (Sin Concentraciones Negativas).



Fuente: Elaboración Propia.

La Figura 22 presenta datos de concentraciones con una tendencia de asimetría negativa, al mismo tiempo, los bigotes inferiores se extienden hasta cero, agosto y septiembre, son los meses con mayor variación.

Figura 23: Concentraciones Mensuales de NO₂ Estratosférico.




Fuente: Elaboración Propia.

UCUENCA

La Figura 23 presenta las concentraciones mensuales promedio de NO₂ estratosférico, en estas figuras se puede apreciar que la Figura 23H es el mes con la concentración máxima más alta, por otra parte, la Figura 23L presenta la concentración máxima más baja. El NO₂ estratosférico no presenta vacíos de información, el área de dispersión de los contaminantes se muestra variable a lo largo del año y no se encuentra regionalizada.


Figura 24: Concentraciones Mensuales de NO₂ Estratosférico.



Fuente: Elaboración Propia.

La Figura 24 presenta una distribución simétrica en los meses de enero, septiembre y noviembre, con el resto de meses con excepción de octubre, presentan una asimetría positiva.

Figura 25: Concentraciones Mensuales de NO₂ Total.




Fuente: Elaboración Propia.

UCUENCA

En la Figura 25 se presentan las concentraciones mensuales promedio de NO₂ Total, en estas figuras se puede apreciar que en la Región Amazónica predominan las concentraciones bajas, mientras que en las provincias Guayas, parte de la Región Costa, y en la unión de Pichincha y Santo Domingo de los Tsáchilas, parte de la Región Interandina, presentan focos de concentraciones máximas.

Figura 26: Concentraciones Mensuales de NO₂ Total.




Fuente: Elaboración Propia.

En la Figura 26 presenta principalmente una asimetría negativa, a la vez que los bigotes muestran una mayor dispersión de datos por encima de la mediana, las concentraciones no son constantes y presentan ligeros cambios a lo largo del tiempo de estudio.


4.1.4.2 Concentraciones Anuales de los diferentes gases de efecto invernadero.

Figura 27: Concentraciones de GEI Promedio Anual (Con Concentraciones Negativas).



Fuente: Elaboración Propia.

Figura 28: Concentraciones de GEI Promedio Anual (Sin Concentraciones Negativas).



Fuente: Elaboración Propia.

UCUENCA

Para entender la Figura 27 hay que considerar que A representa al CO, B al O₃, C al SO₂, D al NO₂ Troposférico, E al NO₂ Estratosférico y finalmente F al NO₂ Total, la Figura 28 tiene la misma denominación que la Figura 27, con variaciones en las subfiguras C y D. La falta de datos en las subfiguras C han disminuido completamente, por su parte las subfiguras D aún presenta falta de datos, en las subfiguras E y F se puede apreciar que en ambos los focos de concentración máxima son los mismos, las subfiguras A y B se encuentran regionalizados, utilizando a la Cordillera de los Andes como barrera natural.

4.1.5 Relación entre la Temperatura y las Variables.

Antes de poder calcular tanto la regresión lineal simple como la regresión lineal múltiple fue necesario realizar un proceso de reensamble, para lo cual se utilizó el método bilineal que es parte del package “raster” del programa RStudio, posteriormente se realizó uso de los scripts de regresión que vienen preinstalados en el programa.

Para la regresión lineal se consideraron a los gases como una variable independiente, mientras la temperatura ocupó el lugar de la variable dependiente, en la Tabla 5 se presenta un resumen de los resultados obtenidos para cada gas.

Tabla 5: Coeficiente R²: Regresión Lineal Simple.

	Ene.	Feb.	Mar.	Abr.	May.	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.	Anual.
CO	0,131	0,086	0,019	0,149	0,293	0,313	0,282	0,180	0,221	0,286	0,301	0,306	0,298
SO₂	0,000	0,018	0,000	0,003	0,004	0,000	0,015	0,003	0,053	0,029	0,037	0,000	0,037
SO₂ (0)	0,006	0,013	0,008	0,000	0,006	0,004	0,055	0,003	0,061	0,042	0,063	0,003	0,039
O₃	0,198	0,173	0,239	0,154	0,098	0,187	0,127	0,176	0,348	0,140	0,137	0,190	0,154
NO₂ Estratosférico	0,023	0,095	0,049	0,116	0,092	0,226	0,156	0,119	0,004	0,004	0,000	0,157	0,073
NO₂ Troposférico	0,083	0,043	0,065	0,164	0,142	0,176	0,174	0,246	0,241	0,265	0,245	0,326	0,228
NO₂ Troposférico (0)	0,089	0,043	0,066	0,169	0,147	0,183	0,180	0,251	0,244	0,266	0,248	0,332	0,229
NO₂ Total	0,358	0,377	0,298	0,251	0,302	0,284	0,286	0,298	0,349	0,297	0,312	0,447	0,353

Fuente: Elaboración Propia.

UCUENCA

La Tabla 5 presenta los resultados de R^2 para cada mes, el SO_2 (0) son los valores de regresión calculados para el SO_2 cuando las concentraciones negativas han sido restablecidas como cero, del mismo modo, se considera el NO_2 Troposférico (0), como los valores obtenidos al sustituir los valores negativos por cero.

El gas con un mayor ajuste es el NO_2 Total, con valores de R^2 que oscilan desde los 0,251 hasta los 0,447, y su contraparte sería el SO_2 con datos que oscilan del 0,000 hasta el 0,053, junto al NO_2 Estratosférico con valores entre 0,000 y 0,226.

La variación resultante entre los dos tipos de NO_2 Troposférico fue mínima para todos los meses, por otra parte, el SO_2 no compartió este comportamiento en su totalidad, puesto que en los meses de julio, noviembre y octubre sus concentraciones cambiaron de 0,015, 0,029 y 0,037 a 0,055, 0,042 y 0,063 respectivamente, mientras en los otros casos la variación no fue superior a 0,01.

Tabla 6: Coeficiente R^2 : Regresión Lineal Múltiple.

	CON CONCENTRACIONES NEGATIVAS.	SIN CONCENTRACIONES NEGATIVAS.
ENERO	0,551	0,554
FEBRERO	0,628	0,628
MARZO	0,607	0,611
ABRIL	0,442	0,443
MAYO	0,582	0,588
JUNIO	0,551	0,555
JULIO	0,539	0,547
AGOSTO	0,424	0,430
SEPTIEMBRE	0,504	0,512
OCTUBRE	0,561	0,565
NOVIEMBRE	0,508	0,512
DICIEMBRE	0,692	0,694
ANUAL	0,606	0,592

Fuente: Elaboración Propia.

La Tabla 6 por su parte presenta que los gases en su conjunto tienen una influencia sobre la temperatura por encima del 0,424, al emplear las concentraciones negativas, mientras que, al considerar las concentraciones negativas como cero, el

UCUENCA

valor de R^2 es ligeramente superior, siendo este de 0,430, la variación existente en ambos casos fue inferior a 0,01, por tanto, en ambos casos presentan una influencia mayor con respecto a los gases evaluados individualmente.

4.2 DISCUSIÓN.

En este tema de investigación se evaluó la relación entre la Temperatura y los Gases de Efecto Invernadero, la influencia individual de los gases era muy baja a comparación de su influencia como grupo. Adicionalmente de manera secundaria se analizaron brevemente los métodos de interpolación IDW y Kriging Simple, para determinar cual tenía una mayor precisión.

4.2.1 *Comparación entre los métodos IDW y Kriging Simple.*

Tanto el método de interpolación IDW como Kriging Simple demostraron tener un buen ajuste durante el análisis, siendo el método IDW el que tuvo un ajuste ligeramente mejor, con un MAE de 0,02 a comparación de Kriging Simple que obtuvo un 0,12, una RMSD de 0,20 contra 0,53, y MAPE de 0,15 en el IDW y de 0,89 en el Kriging Simple, los resultados de R^2 fueron de 0,993 en ambos casos, mientras el AIC fue de 1,783 para IDW y 1,781 para Kriging Simple.

Por tanto, ambos métodos son adecuados, pero se ha visto que la densidad de puntos influye en precisión de los métodos. Cuando la densidad de información es pequeña, la distancia entre los puntos se vuelve mayor, lo cual afecta especialmente al método Kriging, puesto que los semi variogramas que emplea en su fundamento estadístico se vuelven más complejos y difíciles de obtener (Yang et al., 2022), lo que a su vez disminuye su precisión, y en esos casos el método IDW presenta una mejor precisión, como lo fue en nuestro caso, puesto que trabajamos con 56 estaciones a nivel nacional (Munyati & Sinthumule, 2021).

UCUENCA

Si bien, la respuesta obvia sería trabajar con más estaciones y con un tamaño de píxel más pequeño, el tamaño de píxel presentaría un problema diferente, el cual sería la capacidad computacional requerida para llevar a cabo esta operación, de este modo, un píxel más pequeño, significaría una mayor densidad de puntos, y una mejor precisión por parte del método Kriging, pero a su vez significaría un mayor costo y capacidad computacional requeridos. Por otra parte, aumentar el número de estaciones, requeriría una mayor inversión por parte del estado para el mantenimiento de las mismas y de este modo ofrecer datos válidos, esto se ve reflejado en el porcentaje de estaciones que no sobrepasaron el control de calidad, el porcentaje de estaciones que no superaron este primer criterio de evaluación fue del 10 %.

4.2.2 Relación entre la Temperatura y los Gases de Efecto Invernadero.

El satélite Sentinel 5P presenta ligeros problemas con respecto a la toma de datos de las concentraciones de SO₂ y NO₂ Troposférico, al presentar vacíos de información, por otra parte, ambos presentan valores de concentraciones negativas, lo cual pareciera no tener lógica, hasta que se analiza el cómo se obtienen los datos a través del sensor TROPOMI del satélite Sentinel 5P.

Los valores obtenidos la columna de SO₂ presenta la menor relación existente con respecto a la temperatura, pero a la vez es lo que tiene mayor cantidad de valores perdidos o faltantes (VF) lo cual estaría constituido por los píxeles vacíos, lo cual podría ser explicado debido a que el SO₂ es catalogada como un GEI de vida corta, con un tiempo de vida promedio de 25 horas, para que posteriormente el 50 % de este se deposite nuevamente en la superficie, mientras el otro 50 % reaccione formando distintos compuestos químicos (Cuesta et al., 2018).

UCUENCA

Considerando el párrafo anterior con respecto al SO_2 , se puede decir que posee una relación negativa con la temperatura, de tal modo, que a mayor concentración de este contaminante habrá menor temperatura. Sin embargo, nuestro análisis determina que dicha relación no existe, o es prácticamente inexistente, el estudio pudo verse alterado por los valores perdidos, así como un periodo de estudio relativamente corto, se decidió trabajar con los valores con ambos tipos de datos, con concentraciones negativas y reemplazando estas por cero, para verificar las afirmaciones de la ESA con respecto a estos gases y la utilización de las concentraciones negativas.

El CO es resultado de la combustión incompleta de gases contenidos en la gasolina y gases procedentes del petróleo se considera también un gas de efecto invernadero indirecto, puesto que no actúa directamente en el cambio climático, es decir este gas posee radicales libres hidroxilos (OH) los mismos que tienen una amplia cantidad de reacciones que oxidan tanto Carbono, Nitrógeno y Azufre, entonces por la cantidad de CO afectan indirectamente a gases como CH_4 y O_3 troposférico (Acosta & Martínez, 2006).

Todo lo dicho anteriormente es sobre el CO, el CO demuestra una relación media con respecto a la temperatura, lo cual no parece estar muy relacionado con el hecho de que el CO_2 es el principal GEI, y que el CO sea una de sus principales fuentes de origen, ya que es un gas inestable.

El NO_2 Total fue el que mejor ajuste tuvo individualmente, lo cual concuerda con lo establecido en el Informe de la WMO (World Meteorological Organization) "The State of Greenhouse Gases in the Atmosphere Based on Global Observations through 2020", presentado por Barrie & Braathen, (2021), el óxido nitroso representa alrededor del 7 % del forzamiento radiactivo de los GEI, y es el tercer contribuyente individual

UCUENCA

más importante al forzamiento combinado. Esto se ve reforzado por estudios en los cuales se establece que el NO_2 no solo afecta al medio ambiente de manera directa, al ser la principal fuente de Material Particulado 2,5 ($\text{PM}_{2,5}$), sino que también es un precursor de O_3 (Kang et al., 2021).

En nuestro estudio el O_3 ocupa el segundo lugar como el GEI más influyente, sin embargo, presenta un problema, la densidad total de la columna de O_3 está menos correlacionada con las concentraciones superficiales que la densidad de la columna troposférica, por lo que los datos observados por el sensor satelital no tienen una relación lineal simple con las concentraciones cercanas a la superficie (Kang et al., 2021), y esto puede a su vez generar errores al momento del cálculo, por otra parte, este error puede corregirse si se emplea la columna de ozono troposférico que fue liberado en la última actualización de Sentinel 5P.

Otro factor a considerar con respecto a la variación de la temperatura superficial de una zona es el cambio de uso de suelo, esto debido a que las variaciones en el paisaje pueden generar importantes implicaciones climáticas a nivel local, regional e inclusive global. En algunas ocasiones la aportación del cambio de uso de suelo al cambio climático puede ser mayores que las generadas por los GEI, esto a causa de que el incremento de la zona urbana implica la expansión de la superficie edificada e impermeable que intensifica las islas de calor, lo que a su vez implica un importante aumento en la temperatura superficial (Dirmeyer, P et al., 2010; Jiang, J., & Tian, G., 2010; Kalnay, E., & Cai, M., 2003;).

5 CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

Una vez identificados los gases y realizado el análisis respectivo podemos notar una leve relación entre los gases estudiados individualmente y la temperatura superficial, pero este resultado obtenido varía cuando se utilizan los gases en conjunto ahí se puede observar una mayor relación entre los gases estudiados y la temperatura, un aspecto importante a considerar es la disponibilidad, calidad y cantidad de datos obtenidos para el estudio, puesto que una mayor cantidad de datos permitirá tener resultados más precisos.

El sensor remoto Sentinel 5P demostró que su alcance temporal es útil, debido a que, al ser de carácter diario presenta información actualizada y gratuita, sin embargo, se requieren de más estudios para determinar su eficacia para el Ecuador, esto en vista de que se encontraron valores perdidos en las columnas de NO₂ Troposférico y SO₂.

Individualmente el NO₂ Total es el GEI con mayor influencia, seguido por el O₃, mientras que el SO₂ demostró tener la menor influencia individual.

Las concentraciones negativas de SO₂ y NO₂ Troposférico demostraron ser similares en sus dos versiones estudiadas, por tanto, estas pueden ser usadas tal como afirmaba la ESA.

Dependiendo de la densidad de información el método Kriging Simple pierde su efectividad y su competitividad con el método IDW, esto se debe al fundamento estadístico del método Kriging Simple, en el cual considera a la distancia de los datos como proporcional.

El cambio de uso de suelo es un factor importante al determinar la temperatura superficial en una zona urbana, por tanto, al no considerarlo este puede afectar a los

UCUENCA

resultados del estudio. Ya que afecta al albedo, a la temperatura superficial, al grado de absorción de la radiación solar, a las tasas de evaporación, a la transmisión de calor al suelo, al almacenamiento de calor, a la turbulencia del viento.

5.2 RECOMENDACIONES

- A pesar de no tener mayor relevancia con respecto a la influencia de las concentraciones, se recomienda trabajar con concentraciones con valor mínimo de cero, esto para una mayor facilidad de comprensión de los mapas generados.
- Si bien para nuestra investigación se descartaron estaciones con un umbral de VF superior al 10, se podría utilizar un umbral mayor de VF, sin embargo, para que los rellenos de VF sean más robustos se podría utilizar técnicas más complejas como machine learning en lugar de usar técnicas tradicionales, de esta manera se tendrían más datos en tierra generando de esta manera resultados más precisos.

6 BIBLIOGRAFÍA

Acosta, N., & Martínez, C. (2006). *Measurement Of Ambient Carbon Monoxide At The Asuncion City*.

Acuña, E., & Rodriguez, C. (2004). The Treatment of Missing Values and its Effect on Classifier Accuracy. In *Classification, Clustering, and Data Mining Applications* (pp. 639–647). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-17103-1_60

Aguirre, N., Ojeda, T., & Eguiguren, P. (2010). *El cambio climático y la conservación de la biodiversidad en el Ecuador. Artículos de investigación Acuacultura*. 1, 17.

Álvarez, J., Zabala, M., Ruilova, J., & Vinuesa, R. (2020). *Study of the Effects of the Troposphere on the GPS L1 Signal in Riobamba city*.

Aránguez, E., María Ordóñez, J., Serrano, J., Aragonés, N., Fernández-Patier, R., Gandarillas, A., & Galán, I. (1999). Contaminantes Atmosféricos Y Su Vigilancia. In *Rev Esp Salud Pública* (Vol. 73).

Arboleda, A., & Vásquez, J. (2021). *Evaluación De Datos Satelitales Del Sensor De Calidad De Aire TROPOMI Sentinel 5P para el Ecuador entre los Años 2018 a 2020*.

Baethgen, W., & Martino, D. (2000). *Cambio Climático, Gases de Efecto Invernadero e Implicancias en los Sectores Agropecuario y Forestal del Uruguay*.

Ballester, F. (2005). Air Pollution, Climate Change and Health. *Revista Española de Salud Pública*, 79(2), 159–175. <https://doi.org/10.1590/S1135-57272005000200005>

Ballester, F., Iñiguez, C., Sáez, M., Pérez, S., Daponte, A., Ordóñez, J., Barceló, A., Taracido, M., Arribas, F., Bellido, J., Cambra, K., Cañada, Á., & Guillén, J. (2003). Relación a corto plazo de la contaminación atmosférica y la mortalidad en 13 ciudades españolas. *Medicina Clínica*, 121(18), 684–689. [https://doi.org/10.1016/S0025-7753\(03\)74063-9](https://doi.org/10.1016/S0025-7753(03)74063-9)

Barreto, S. (2009). *Transformaciones Geométricas Sobre Imágenes Digitales*.

Barrie, L., & Braathen, G. (2021). *WMO Greenhouse Gas Bulletin The State of Greenhouse Gases in the Atmosphere Based on Global Observations through 2020*. <https://ig3is.wmo.int/>,

Bello, P., Rodríguez, E., Prado, R., & Rivas, S. (2019). Contaminación por ozono, estrés oxidativo, plasticidad sináptica y neurodegeneración. *Neurología*. <https://doi.org/10.1016/j.nrl.2018.10.003>

Benavides, O., & León, G. (2007). *Información Técnica Sobre Gases De Efecto Invernadero Y El Cambio Climático*.

Bolaños, P., & Chacón, C. (2017). *REVISIÓN BIBLIOGRÁFICA INTOXICACION POR MONOXIDO DE CARBONO*. 34(1).

Boucher, R., & Wu, J. (2009). *Applied Geostatistics with SGeMS: A user's guide* (1st ed.).

Caballero, M., Lozano, S., & Ortega, B. (2007). *Efecto invernadero, calentamiento global y cambio climático: una perspectiva desde las ciencias de la Tierra*. <http://www.revista.unam.mx/vol.8/num10/art78/int78.htm>

Chen, D., Zhang, F., Zhang, M., Meng, Q., Jim, C. Y., Shi, J., Tan, M. L., & Ma, X. (2022). Landscape and vegetation traits of urban green space can predict local surface temperature. *Science of The Total Environment*, 825, 154006. <https://doi.org/10.1016/j.scitotenv.2022.154006>

Cheng, C., Shalabh, & Garg, G. (2014). Coefficient of determination for multiple measurement error models. *Journal of Multivariate Analysis*, 126, 137–152. <https://doi.org/10.1016/j.jmva.2014.01.006>.

Copernicus Sentinel-5P (procesado por ESA), 2021, TROPOMI Level 2 Carbon Monoxide total column products. Version 02. European Space Agency. <https://doi.org/10.5270/S5P-bj3nry0>.

Copernicus Sentinel-5P (procesado por ESA), 2021, TROPOMI Level 2 Nitrogen Dioxide total column products. Version 02. European Space Agency. <https://doi.org/10.5270/S5P-9bnp8q8>.

Copernicus Sentinel-5P (procesado por ESA), 2020, TROPOMI Level 2 Ozone Total Column products. Version 02. European Space Agency. <https://doi.org/10.5270/S5P-ft13p57>.

Copernicus Sentinel-5P (procesado por ESA) (2020) TROPOMI Level 2 Sulphur Dioxide Total Column. Version 02. European Space Agency. <https://doi.org/10.5270/S5P-74eidii>.

Cuesta A., González, C., Velasco, M., & Aristizábal, B. (2018). Distribución Espacial De Concentraciones De So₂, Nox Y O₃ En El Aire Ambiente De Manizales. *Revista Internacional de Contaminacion Ambiental*, 34(3), 489–504. <https://doi.org/10.20937/RICA.2018.34.03.11>

Dagnino, J. (2014). *Datos Faltantes (Missing Values)*.

Delgado, C., & Ovalle, N. (2018). *Análisis espacial y temporal de la concentración de NO₂ troposférico en cuatro áreas urbanas de Colombia para el periodo entre 2005 y 2016*. https://ciencia.lasalle.edu.co/ing_ambiental_sanitaria//ciencia.lasalle.edu.co/ing_ambiental_sanitaria/750.

Dirmeyer, P., Niyogi, D., de Noblet, N., Dickinson, R. E., & Snyder, P. K. (2010). Impacts of land use change on climate. *International Journal of Climatology*, 30(13), 1905–1907. <https://doi.org/10.1002/joc.2157>

Dominguez, J. (2000). *Breve Introducción a la Cartografía y a los Sistemas de Información Geográfica (SIG)*. <https://www.researchgate.net/publication/237467702>

EMOV. (2021). *Informe de la Calidad del Aire de Cuenca 2020*.

ESA. (2017). *The European Space Agency (ESA). Sentinel-5P TROPOMI User Guide*. .

Escobar, I. (1997). *Contaminación Ambiental*.

Etemadi, S., & Khashei, M. (2021). Etemadi multiple linear regression. *Measurement*, 186, 110080. <https://doi.org/10.1016/j.measurement.2021.110080>

Forero, D. (2019). *Metodología Para La Incorporación De Datos Del Sensor Tropomi Del Satélite Sentinel 5-P Al Monitoreo De La Calidad Del Aire*.

García, M., Ramírez, H., Meulenert, Á., García, F., Alcalá, J., Arellano, J., Espinosa, M., & De la Torre, O. (2006). *Influencia de contaminates para lluvia acida Related papers*. <http://www.redalyc.org/articulo.oa?id=73000407>

González, Y., Fernández, Y., & Gutiérrez, T. (2013). *El cambio climático y sus efectos en la salud*. <http://scielo.sld.cu>

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>

Graedel, T. (2012). *Chemical compounds in the atmosphere*.

Gutiérrez, A., Ferrero, A., Estarlich, M., Esplugues, A., Iñiguez, C., & Ballester, F. (2018). Exposure to nitrogen dioxide and respiratory health at 2 years in the INMA-Valencia cohort. *Gaceta Sanitaria*, 32(6), 507–512. <https://doi.org/10.1016/j.gaceta.2017.05.012>

Hackeloeer, A., Klasing, K., Krisp, J. M., & Meng, L. (2014). Georeferencing: a review of methods and applications. *Annals of GIS*, 20(1). <https://doi.org/10.1080/19475683.2013.868826>

Hadeed, S., O'Rourke, M., Burgess, J., Harris, R., & Canales, R. (2020). Imputation methods for addressing missing data in short-term monitoring of air pollutants. *Science of The Total Environment*, 730, 139140. <https://doi.org/10.1016/j.scitotenv.2020.139140>

Hernández, M. (2010). *Suelos de humedales como sumideros de carbono y fuentes de metano*.

Hill, L. (2009). *Georeferencing: The geographic associations of information*.

Ialongo, I., Virta, H., Eskes, H., Hovila, J., & Douros, J. (2019). Comparison of TROPOMI/Sentinel 5 Precursor NO₂ observations with ground-based

measurements in Helsinki. *Atmospheric Measurement Techniques Discussions*, 2. <https://doi.org/10.5194/amt-2019-329>

Ingdal, M., Johnsen, R., & Harrington, D. A. (2019). The Akaike information criterion in weighted regression of immittance data. *Electrochimica Acta*, 317, 648–653. <https://doi.org/10.1016/j.electacta.2019.06.030>

Intergovernmental Panel On Climate Change, IPCC. (1995). *Second Assessment Climate Change 1995*.

Intergovernmental Panel On Climate Change IPCC. (2001). *Third Assessment Report: Climate Change 2001*.

Jiang, J., & Tian, G. (2010). Analysis of the impact of Land use/Land cover change on Land Surface Temperature with Remote Sensing. *Procedia Environmental Sciences*, 2, 571–575. <https://doi.org/10.1016/j.proenv.2010.10.062>.

Kalnay, E., & Cai, M. (2003). Impact of urbanization and land-use change on climate. *Nature*, 423(6939), 528–531. <https://doi.org/10.1038/nature01675>

Kang, Y., Choi, H., Im, J., Park, S., Shin, M., Song, C.-K., & Kim, S. (2021). Estimation of surface-level NO₂ and O₃ concentrations using TROPOMI data and machine learning over East Asia. *Environmental Pollution*, 288, 117711. <https://doi.org/10.1016/j.envpol.2021.117711>

Kaplan, G., & Yigit, Z. (2020). Space-Borne Air Pollution Observation From Sentinel-5P TROPOMI: Relationship Between Pollutants, Geographical and Demographic Data. *International Journal of Engineering and Geosciences*. <https://doi.org/10.26833/ijeg.644089>

Lee, W. (2013). Akaike's Theorem and weak predictivism in science. *Studies in History and Philosophy of Science Part A*, 44(4), 594–599. <https://doi.org/10.1016/j.shpsa.2013.06.001>

López, E., Posada, C., & Moreno, J. (2006). *Los Sistemas De Información Geográfica*.

Lu, G., & Wong, D. (2008). An adaptive inverse-distance weighting spatial interpolation technique. *Computers & Geosciences*, 34(9), 1044–1055. <https://doi.org/10.1016/j.cageo.2007.07.010>

Ludeña, C., & Wilk, D. (2013). *ECUADOR: Mitigación y Adaptación al Cambio Climático Marco de la preparación de la Estrategia 2012-2017 del BID en Ecuador*.

MAAE. (2019). *Norma De Calidad Del Aire Ambiente*.

Martínez, J., & Fernández, A. (2004). *Cambio climático: una visión desde México*.

Matus C., & Lucero, R. (2002). Norma Primaria de calidad del aire. *Revista Chilena de Enfermedades Respiratorias*, 18(2). <https://doi.org/10.4067/S0717-73482002000200006>

Munyati, C., & Sinthumule, N. I. (2021). Comparative suitability of ordinary kriging and Inverse Distance Weighted interpolation for indicating intactness gradients on threatened savannah woodland and forest stands. *Environmental and Sustainability Indicators*, 12, 100151. <https://doi.org/10.1016/j.indic.2021.100151>

Olaya, V. (2014). *Sistemas de Información Geográfica*.

Oxoli, D., Cedeño, J., & Brovelli, M. (2020). Assessment of sentinel-5P performance for ground-level air quality monitoring: Preparatory experiments over the Covid-19 lockdown period. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 54(3/W1), 111–116. <https://doi.org/10.5194/isprs-archives-XLIV-3-W1-2020-111-2020>

Oyarzún, M. (2010). Contaminación aérea y sus efectos en la salud. *Revista Chilena de Enfermedades Respiratorias*, 26(1). <https://doi.org/10.4067/S0717-73482010000100004>

Pal, S., & Ziaul, Sk. (2017). Detection of land use and land cover change and land surface temperature in English Bazar urban centre. *The Egyptian Journal of Remote Sensing and Space Science*, 20(1), 125–145. <https://doi.org/10.1016/j.ejrs.2016.11.003>

Pérez, C., & Muñoz, Á. (2006). *Teledetección: Nociones y Aplicaciones*.

Perilla, G., & Mas, J. (2020). Google Earth Engine - GEE: A powerful tool linking the potential of massive data and the efficiency of cloud processing. *Investigaciones Geográficas*, 101. <https://doi.org/10.14350/rig.59929>

Pindyck, R., & Rubinfeld, D. (2001). *Econometría: modelos y pronósticos*.

Portet, S. (2020). A primer on model selection using the Akaike Information Criterion. *Infectious Disease Modelling*, 5, 111–128. <https://doi.org/10.1016/j.idm.2019.12.010>

Prion, S., & Haerling, K. (2020). Making Sense of Methods and Measurements: Simple Linear Regression. *Clinical Simulation in Nursing*, 48, 94–95. <https://doi.org/10.1016/j.ecns.2020.07.004>

Pujadas, M. (2004). *Formación Y Transporte De Dióxido De Nitrógeno En La Cuenca Aérea De Madrid En Situaciones Episódicas De Invierno*.

Rajab, J., MatJafri, M., Lim, H., Abdullah, K., & Hassan, F. (2011). The relationship between air surface temperature and greenhouse gases in Peninsular Malaysia during 2003–2008 retrieved from AIRS data. *Proceeding of the 2011 IEEE International Conference on Space Science and Communication (IconSpace)*, 28–33. <https://doi.org/10.1109/IconSpace.2011.6015846>

Rivero, D. (2019). Spirometry: Basic concepts. *Revista Alergia Mexico*, 66(1), 76–84. <https://doi.org/10.29262/ram.v66i1.536>

Sánchez, F. (2006). *Consideraciones sobre la capa de ozono y su relación con el cáncer de piel The relationship between the ozone layer and skin cancer*.

Sánchez, J., Romieu, I., Ruiz, S., Pino, P., & Gutiérrez, M. (1999). *Efectos agudos de las partículas respirables y del dióxido de azufre sobre la salud respiratoria en niños del área industrial de Puchuncaví, Chile*.

Secretaría de Ambiente. (2020). *Investigación Análisis Y Monitoreo Red Metropolitana De Monitoreo Atmosférico De Quito* www.quitoambiente.gob.ec.

Shepherd, T. (2000). The middle atmosphere. *Journal of Atmospheric and Solar-Terrestrial Physics*, 62(17–18), 1587–1601. [https://doi.org/10.1016/S1364-6826\(00\)00114-0](https://doi.org/10.1016/S1364-6826(00)00114-0)

Téllez, J., Rodríguez, A., & Fajardo, A. (2006). [Carbon monoxide contamination: an environmental health problem]. *Revista de Salud Pública (Bogotá, Colombia)*, 8(1), 108–117. <https://doi.org/10.1590/S0124-00642006000100010>

Toro, G., & Melo, C. (2009). *Application of geostatistical interpolation methods for casting of digital levels by a satellite image with lines missing and salt and pepper effect*.

Tsagouri, I. (2022). Space Weather Effects on the Earth's Upper Atmosphere: Short Report on Ionospheric Storm Effects at Middle Latitudes. *Atmosphere*, 13(2), 346. <https://doi.org/10.3390/atmos13020346>

Un viejo gas nuevo, el monóxido de carbono (CO): fundamentos en Biología humana, Patobiología, Bioclínica y Farmacoterapéutica humana. (n.d.). Retrieved February 25, 2022, from http://www.scielo.org.co/scielo.php?pid=S0121-07932008000300009&script=sci_abstract&tlng=en

Veefkind, J., Aben, I., McMullan, K., Förster, H., de Vries, J., Otter, G., Claas, J., Eskes, H. J., de Haan, J. F., Kleipool, Q., van Weele, M., Hasekamp, O., Hoogeveen, R., Landgraf, J., Snel, R., Tol, P., Ingmann, P., Voors, R., Kruizinga, B., ... Levelt, P. F. (2012). TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications. *Remote Sensing of Environment*, 120, 70–83. <https://doi.org/10.1016/j.rse.2011.09.027>

Villavicencio, M. (1858). *Geografía de la República del Ecuador*. R. Craighead.

Yang, M., Zhang, D., Wang, F., & Han, X. (2022). Efficient local adaptive Kriging approximation method with single-loop strategy for reliability-based design optimization. *Computer Methods in Applied Mechanics and Engineering*, 390, 114462. <https://doi.org/10.1016/j.cma.2021.114462>

Zheng, Yang, Wu, & Marinello. (2019). Spatial Variation of NO₂ and Its Impact Factors in China: An Application of Sentinel-5P Products. *Remote Sensing*, 11(16), 1939. <https://doi.org/10.3390/rs11161939>

7.1 Anexo 1: Comandos de obtención de imágenes de Google

Earth Engine.

7.1.1 CO.

```
//Datos Sentinel 5P para CO

var CO = ee.ImageCollection('COPERNICUS/S5P/OFFL/L3_CO')

    .filterDate('2019-01-01', '2020-01-01'); //Selección de periodo temporal

//Datos para columna de CO

var SentinelCO = CO

    .select('CO_column_number_density')

    .filterBounds (geometry);

var COData = ee.Image(SentinelCO.median());

var COClip = COData.clip (geometry);

Map.addLayer (COClip, {

    max: 0.05,

    min: 0.0,

    palette: ["black", "blue", "purple", "cyan", "green", "yellow", "red"]},

'CO');

print(SentinelCO.size());

var dates = ee.List(SentinelCO.aggregate_array("system:time_start"))

    .map(function(d){return ee.Date(d)});
```

```
print(dates);
```

```
Export.image.toDrive({  
  image: COClip.select("CO_column_number_density"),  
  description: 'CO',  
  scale: 1100,  
  region: geometry});
```

7.1.2 NO₂.

Datos Sentinel 5P para NO₂

```
var N02 = ee.ImageCollection('COPERNICUS/S5P/OFFL/L3_NO2')  
  .filterDate('2019-01-01', '2020-01-01'); //Selección de periodo temporal
```

7.1.2.1 NO₂ Total.

```
var SentinelNO2Total = N02  
  .select('NO2_column_number_density')  
  .filterBounds (geometry);  
var NO2TotalData = ee.Image(SentinelNO2Total.median());  
var NO2TotalClip = NO2TotalData.clip (geometry);  
Map.addLayer (NO2TotalClip, {  
  max: 0.0002,  
  min: 0.0,  
  palette: ["black", "blue", "purple", "cyan", "green", "yellow", "red"]},  
  'NO2 Total');
```


UCUENCA

```
print(SentinelNO2Total.size());
```

```
var dates = ee.List(SentinelNO2Total.aggregate_array("system:time_start"))  
.map(function(d){return ee.Date(d)});  
print(dates);
```

```
Export.image.toDrive({  
  image: NO2TotalClip.select("NO2_column_number_density"),  
  description: 'NO2_Total',  
  scale: 1100,  
  region: geometry});
```

7.1.2.2 NO₂ Troposférico.

```
var SentinelNO2Tropo = N02  
.select('tropospheric_NO2_column_number_density')  
.filterBounds (geometry);  
var NO2TropoData = ee.Image(SentinelNO2Tropo.median());  
var NO2TropoClip = NO2TropoData.clip (geometry);  
Map.addLayer (NO2TropoClip, {  
  max: 0.0002,  
  min: 0.0,  
  palette: ["black", "blue", "purple", "cyan", "green", "yellow", "red"]},  
  'NO2 Troposférico');  
  
print(SentinelNO2Tropo.size());
```

UCUENCA

```
var dates = ee.List(SentinelNO2Tropo.aggregate_array("system:time_start"))
  .map(function(d){return ee.Date(d)});
print(dates);
```

```
Export.image.toDrive({
  image: NO2TropoClip.select("tropospheric_NO2_column_number_density"),
  description: 'NO2_Troposferico',
  scale: 1100,
  region: geometry});
```

7.1.2.3 NO₂ Estratosférico.

```
var SentinelNO2Estr = N02
  .select('stratospheric_NO2_column_number_density')
  .filterBounds (geometry);

var NO2EstrData = ee.Image(SentinelNO2Estr.median());
var NO2EstrClip = NO2EstrData.clip (geometry);

Map.addLayer (NO2EstrClip, {
  max: 0.00005,
  min: 0.0,
  palette: ["black", "blue", "purple", "cyan", "green", "yellow", "red"]},
'NO2 Estratosférico');

print(SentinelNO2Estr.size());

var dates = ee.List(SentinelNO2Estr.aggregate_array("system:time_start"))
  .map(function(d){return ee.Date(d)});
```

```
print(dates);
```

```
Export.image.toDrive({  
  image: NO2EstrClip.select("stratospheric_NO2_column_number_density"),  
  description: 'NO2_Estratosferico',  
  scale: 1100,  
  region: geometry});
```

7.1.3 O₃.

```
//Datos Sentinel 5P para O3
```

```
var O3 = ee.ImageCollection('COPERNICUS/S5P/OFFL/L3_O3')
```

```
.filterDate('2019-01-01', '2020-01-01'); //Selección de periodo temporal
```

```
//Datos para columna O3 Total
```

```
var SentinelO3Total = O3
```

```
.select('O3_column_number_density')
```

```
.filterBounds(geometry);
```

```
var O3TotalData = ee.Image(SentinelO3Total.median());
```

```
var O3TotalClip = O3TotalData.clip(geometry);
```

```
Map.addLayer(O3TotalClip,{
```

```
  max: 0.15,
```

```
  min: 0.12,
```

```
  palette: ["black", "blue", "purple", "cyan", "green", "yellow", "red"]},
```

```
'O3 Total');
```

UCUENCA

```
print(SentinelO3Total.size());
```

```
var dates = ee.List(SentinelO3Total.aggregate_array("system:time_start"))  
.map(function(d){return ee.Date(d)});  
print(dates);
```

```
Export.image.toDrive({  
  image: O3TotalClip.select('O3_column_number_density'),  
  description: 'O3',  
  scale: 1100,  
  region: geometry})
```

7.1.4 SO₂

```
//Datos Sentinel 5P para SO2//
```

```
var SO2 = ee.ImageCollection('COPERNICUS/S5P/OFFL/L3_SO2')  
.filterDate('2019-01-01', '2020-01-01'); //Selección de periodo temporal
```

```
//Datos para columna SO2 Total
```

```
var SentinelSO2Total = SO2  
.select('SO2_column_number_density')  
.filterBounds (geometry);  
var SO2TotalData = ee.Image(SentinelSO2Total.median());  
var SO2TotalClip = SO2TotalData.clip(geometry);  
Map.addLayer (SO2TotalClip,{  
  max: 0.0005,
```

UCUENCA

```
min: 0.0,  
palette: ["black", "blue", "purple", "cyan", "green", "yellow", "red"],  
'SO2 Total');  
  
print(SentinelSO2Total.size());  
  
var dates = ee.List(SentinelSO2Total.aggregate_array("system:time_start"))  
.map(function(d){return ee.Date(d)});  
print(dates);  
  
Export.image.toDrive({  
  image: SO2TotalClip.select('SO2_column_number_density'),  
  description: 'SO2',  
  scale: 1100,  
  region: geometry})
```

7.2 Anexo 2: Cálculo de correlaciones en R-Studio.

7.2.1 Librerías.

- ✓ library(sp)
- ✓ library(raster)
- ✓ library(maptools)
- ✓ library(rgdal)
- ✓ library(devtools)

UCUENCA

7.2.2 *Cálculo de correlaciones.*

```
IDW_anual<-raster("f_IDW_anual.tif")
```

```
SO2_1_anual<-raster("f_SO2_1_anual.tif")
```

```
CO_anual<-raster("f_CO_anual.tif")
```

```
O3_anual<-raster("f_O3_anual.tif")
```

```
NO2_TOT_anual<-raster("f_NO2_Total_anual.tif")
```

```
NO2_TROP_anual<-raster("f_NO2_Trop_anual.tif")
```

```
NO2_ESTR_anual<-raster("f_NO2_Estr_anual.tif")
```

```
SO2_1<-resample(SO2_1_anual,IDW_anual,method="bilinear")
```

```
CO_1<-resample(CO_anual,IDW_anual,method="bilinear")
```

```
O3_1<-resample(O3_anual,IDW_anual,method="bilinear")
```

```
NO2_TOT_1<-resample(NO2_TOT_anual,IDW_anual,method="bilinear")
```

```
NO2_TROP_1<-resample(NO2_TROP_anual,IDW_anual,method="bilinear")
```

```
NO2_ESTR_1<-resample(NO2_ESTR_anual,IDW_anual,method="bilinear")
```

```
IDW<-raster::as.data.frame(IDW_anual,xy=TRUE)
```

```
SO2<-raster::as.data.frame(SO2_1,xy=TRUE)
```

```
CO<-raster::as.data.frame(CO_1,xy=TRUE)
```

UCUENCA

```
O3<-raster::as.data.frame(O3_1,xy=TRUE)
```

```
NO2_TOT<-raster::as.data.frame(NO2_TOT_1,xy=TRUE)
```

```
NO2_TROP<-raster::as.data.frame(NO2_TROP_1,xy=TRUE)
```

```
NO2_ESTR<-raster::as.data.frame(NO2_ESTR_1,xy=TRUE)
```

```
A<-merge.data.frame(IDW,SO2)
```

```
B<-merge.data.frame(A,CO)
```

```
C<-merge.data.frame(B,O3)
```

```
D<-merge.data.frame(C,NO2_TOT)
```

```
E<-merge.data.frame(D,NO2_TROP)
```

```
anual<-merge.data.frame(E,NO2_ESTR)
```

```
r1<-lm(f_IDW_anual~f_SO2_1_anual,data=anual)
```

```
summary(r1)
```

```
r2<-lm(f_IDW_anual~f_CO_anual,data=anual)
```

```
summary(r2)
```

```
r3<-lm(f_IDW_anual~f_O3_anual,data=anual)
```

```
summary(r3)
```

```
r4<-lm(f_IDW_anual~f_NO2_Total_anual,data=anual)
```


UCUENCA

```
summary(r4)
```

```
r5<-lm(f_IDW_anual~f_NO2_Trop_anual,data=anual)
```

```
summary(r5)
```

```
r6<-lm(f_IDW_anual~f_NO2_Estr_anual,data=anual)
```

```
summary(r6)
```

```
r7<-
```

```
lm(f_IDW_anual~f_SO2_1_anual+f_CO_anual+f_O3_anual+f_NO2_Total_anual+f_
NO2_Trop_anual+f_NO2_Estr_anual,data=anual)
```

```
summary(r7)
```