


Presentación del resumen: Monitoreando la variación espacio-temporal del ozono troposférico y sus precursores (NO₂, CO y HCHO) usando imágenes de serie temporal Sentinel-5p basadas en Google Earth Engine: caso en Perú, 2019-2024

Gonzalo Nícolas Martell Rosado Ruiz¹

¹Universidad Peruana Unión, gonzalo.rosado@upeu.edu.pe



Introducción y contexto



Fuente: Infobae (2025), ATV (2023), IDL (2020), Copernicus (2025)

Contaminantes Clave

Ozono (O_3), NO_2 , CO y formaldehído (HCHO) afectan salud y ambiente.


Limitaciones en Perú

Escasa infraestructura terrestre
terrestre dificulta monitoreo ambiental.

Solución Satelital


Sentinel-5P y Google Earth Engine permiten monitoreo espacial y temporal.

Metodología



Adquisición de datos satelitales

Plataforma *Google Earth Engine* (GEE)




- Procesamiento de 4 contaminantes (NO_2 , CO, HCHO, O_3) para 6 años (2019–2024), a 1 km de resolución.
- Generación de 52 imágenes semanales/año → 312 bandas por contaminante.
- Exportación en GeoTIFF multibanda por contaminante y año vía *Export.image.toDrive()*.
- Diseño de pequeña Interfaz UI con botón único para lanzar 24 tareas (4 contaminantes × 6 años).

Procesamiento estadístico y análisis temporal

Plataforma *Google Colab*

- Se procesaron datos geospaciales de contaminantes atmosféricos: O₃, NO₂, CO y HCHO , para múltiples años entre 2019 y 2024.
- Los datos ráster se organizaron por año y banda (hasta 52 bandas por archivo) para análisis detallado.
- Se extrajeron estadísticas por departamento en Perú, incluyendo *min*, *max*, *promedio*, *mediana*, *desvío estándar* e *incertidumbre*.
- El procesamiento se realizó mediante técnicas de paralelización para optimizar el tiempo de cómputo usando todas las bandas disponibles.
- Se generaron gráficos de regresión tipo Theil-Sen para evaluar relaciones entre pares de contaminantes (por ejemplo, O₃ vs NO₂) incluyendo estadísticas como R² y correlación de Pearson.
- Los datos se agruparon por estacionalidad (verano, otoño, invierno y primavera) para identificar patrones temporales.



```

procesamiento_rasters_masivos_03.ipynb
File Edit View Insert Runtime Tools Help
Q Comments + Code + Text

# Ejecutar el procesamiento
estadisticas = calcular_estadisticas(raster_layers_03, gdf)

# Convertir a DataFrame y guardar
df = pd.DataFrame(estadisticas)

# Mostrar las primeras filas del DataFrame
df.head()

Procesando bandas: 100% [11/12] [11:12:09:09, 2.16s/it]

```

Departamento	Contaminante	Año	Banda	Min	Max	Prom	DesvEst	Mediana	Incertidumbre (95%)	Rango	N_píxeles
0	AMAZONAS	O3	2019	0.110400	0.113860	0.112208	0.000989	0.112278	0.000008	0.003470	40970
1	ANCASH	O3	2019	0.110421	0.115093	0.113093	0.000704	0.113026	0.000007	0.004073	37367
2	APURIMAC	O3	2019	0.111256	0.114656	0.112819	0.000598	0.112803	0.000007	0.003400	22414
3	AREQUIPA	O3	2019	0.111009	0.116680	0.113364	0.000915	0.113202	0.000007	0.005072	67224
4	AYACUCHO	O3	2019	0.110503	0.114681	0.112506	0.000548	0.112453	0.000005	0.004118	46320

```

[ ] Import rasterio
import os

# Función para separar las bandas de todos los archivos de raster en un directorio
def separar_bandas_todos_rastros(raster_layers, output_folder):
    band_paths = []

    for contaminante, años in raster_layers.items():
        for año, raster_path in años.items():
            # Abrir cada archivo raster
            with rasterio.open(raster_path) as src:
                base_name = os.path.basename(raster_path).replace(".tif", "")
            # Separar las bandas de cada archivo raster
            for banda in range(1, src.count + 1):
                band_data = src.read(banda)
                band_meta = src.meta.copy()
                band_meta.update(count=1) # Solo una banda por archivo

            # Crear el nombre de archivo para la banda
            output_band_path = os.path.join(output_folder, f"{base_name}_{banda}_{año}.tif")

            # Guardar la banda en un archivo nuevo
            with rasterio.open(output_band_path, "w", **band_meta) as dst:
                dst.write(band_data, 1)
            print(f"Banda {banda} saved to {output_band_path}")


            band_paths.append(output_band_path) # Guardar el path del archivo de la banda

    return band_paths # Lista con todas las rutas a las bandas

```

Visualización espacial y análisis SIG

QGIS 3.42.2 'Münster'





- Los rásteres estacionales se procesaron en QGIS 3.42.1 'Münster' para análisis espacial y cartografía temática.
- Se usó una simbología pseudocolor monobanda (paleta Jet) con clasificación por cuantiles (10 clases) para resaltar variaciones de concentración.
- La representación visual permitió identificar patrones geográficos de los contaminantes (O_3 , NO_2 , CO , $HCHO$) por estación, complementando el análisis estadístico.

Resultados

Tabla 1. Datos estacionales generados de las imágenes ráster para los contaminantes O_3 Troposférico y sus precursores, en mol/m^2 , 2019 al 2024

Contaminante	Estacionalidad	N° de datos (pixeles)	mínimo	máximo	promedio	mediana	desviación estándar	Incertidumbre (95%)
O_3 (mol/m^2)	Invierno	105729844	0.09892018904	0.12946860785	0.11416033495	0.11413331161	0.00103621916	0.00001
	Otoño	105729887	0.10022284688	0.12272998096	0.11177728815	0.11177798987	0.00076630597	0.00000
	Primavera	104391534	0.10555781201	0.13182984784	0.11869330256	0.11868502577	0.00106081885	0.00001
	Verano	101714828	0.10317467372	0.12340885143	0.11375275596	0.11376648154	0.00078748243	0.00000
NO_2 (mol/m^2)	Invierno	105722084	0.00003203083	0.00007941223	0.00004719767	0.00004661138	0.00000575534	0.00000
	Otoño	105715370	0.00002589256	0.00006127471	0.00003914525	0.00003875084	0.00000443336	0.00000
	Primavera	104388585	0.00003223477	0.00007537062	0.00004734887	0.00004686998	0.00000522617	0.00000
	Verano	101664840	0.00002691496	0.00005558937	0.00003897205	0.00003871952	0.00000364263	0.00000
CO (mol/m^2)	Invierno	105147						
	Otoño	104963						
	Primavera	103546						
	Verano	100073						
$HCHO$ (mol/m^2)	Invierno	101914						
	Otoño	94390						
	Primavera	96245						
	Verano	84030						





Análisis de estadística descriptiva e inferencial

Data total – Perú 2019:2024

- **Ozono troposférico (O_3):** máximo en primavera ($1.187 \times 10^{-1} \pm 1.282 \times 10^{-6} \text{ mol/m}^2$), mínimo en otoño ($1.123 \times 10^{-1} \pm 9.869 \times 10^{-7} \text{ mol/m}^2$).
- **Dióxido de nitrógeno (NO_2):** mayor valor en primavera ($4.734 \times 10^{-5} \pm 1.258 \times 10^{-8} \text{ mol/m}^2$), menor en otoño ($3.915 \times 10^{-5} \pm 1.189 \times 10^{-8} \text{ mol/m}^2$).
- **Monóxido de carbono (CO):** concentración más alta en primavera ($3.289 \times 10^{-2} \pm 6.116 \times 10^{-6} \text{ mol/m}^2$), más baja en invierno ($2.522 \times 10^{-2} \pm 4.851 \times 10^{-6} \text{ mol/m}^2$).
- **Formaldehído ($HCHO$):** pico en primavera ($1.006 \times 10^{-4} \pm 9.690 \times 10^{-8} \text{ mol/m}^2$), mínimo en invierno ($1.251 \times 10^{-4} \pm 1.046 \times 10^{-7} \text{ mol/m}^2$).
- Correlaciones entre O_3 y precursores (CO , NO_2 , $HCHO$) son mayormente débiles o inconsistentes ($R^2 < 50\%$).
- Valores moderados se observan entre CO y O_3 en invierno ($R^2 = 53\%$) y otoño ($R^2 = 50\%$), y entre NO_2 y O_3 en invierno ($R^2 = 46\%$).
- Correlaciones bajas o negativas incluyen $CO-HCHO$ en otoño y NO_2-O_3 en otoño ($R^2 = -33\%$). Los resultados sugieren relaciones no generalizables entre estaciones ni contaminantes.




Análisis gráfico por temporalidad (regiones)

- O_3 alcanza máximos en la Amazonía (0.1259 mol/m^2 en 2022), seguido por costa y Andes; los mínimos fluctúan entre regiones, destacando 0.1060 mol/m^2 en los Andes (2024).
- NO_2 predomina en la costa ($6.90 \times 10^{-5} \text{ mol/m}^2$ en 2022), con menores niveles y mayor variabilidad en Amazonía y Andes.
- CO y HCHO presentan sus valores más altos en la Amazonía (0.0943 y 0.0003 mol/m^2 en 2025), mientras que los mínimos se registran en Andes y Amazonía.
- Primavera concentra las mayores concentraciones de O_3 en todas las regiones, mientras que el otoño muestra los valores más bajos.




Análisis de correlación por temporalidad (estaciones)

- CO y HCHO muestran una fuerte correlación (0.60–0.84) en todas las estaciones, tanto en Pearson como Spearman.
- Correlaciones débiles y negativas entre CO y NO₂, especialmente en primavera y verano.
- Relaciones positivas bajas con O₃: CO y HCHO muestran correlaciones ligeras, mientras que NO₂ presenta interacciones cercanas a cero o negativas con O₃.
- R² bajo en la mayoría de las combinaciones, con CO–HCHO alcanzando hasta 0.72.
- Poca capacidad predictiva en las correlaciones entre NO₂ y O₃, con R² bajo (menos de 0.20).



Análisis de distribución geográfica (estacionalidad)

- O_3 : Valores más altos en la región andina (Huancavelica, Junín, Cusco, Puno), constantes en primavera y verano, y disminución en otoño e invierno. Las regiones costeras y amazónicas presentan valores bajos.
- NO_2 : Máximas concentraciones en la costa central y norte (Lima, Callao, La Libertad), principalmente en invierno y otoño. Niveles bajos en las regiones amazónica y andina.
- CO: Altos niveles en la Amazonía (Ucayali, Loreto, Madre de Dios), especialmente en otoño y verano.
- HCHO: Concentraciones elevadas en la Amazonía, más notables en primavera y verano. Las regiones costeras y altoandinas presentan valores bajos.





Discusión

- **Influencia meteorológica y geográfica:** Los patrones estacionales de contaminantes atmosféricos en Perú (2019–2024) muestran una fuerte influencia de factores meteorológicos y geográficos. Por ejemplo, el aumento de ozono (O_3) en primavera y verano podría estar relacionado con mayor radiación solar, que favorece la formación fotoquímica del O_3 a partir de precursores como NO_x y VOCs. Además, las altas concentraciones de CO y HCHO en primavera están asociadas con la quema de biomasa en la Amazonía y procesos de descomposición orgánica.
- **Patrones de ozono y sus precursores:** El análisis de O_3 revela una estacionalidad marcada, con picos recurrentes en primavera, respaldados por un ajuste sinusoidal que explica un 46.5% de su variabilidad. Las concentraciones de NO_2 , CO y HCHO no muestran tendencias lineales significativas, pero sí cierta estacionalidad, especialmente en HCHO y CO. Las concentraciones de O_3 están relacionadas con reacciones fotoquímicas que involucran a NO_x y VOCs.
- **Impacto de la Amazonía y las emisiones biogénicas:** La región amazónica presenta altas concentraciones de CO y HCHO, especialmente en primavera, lo que se atribuye a emisiones biogénicas y la quema de biomasa. Estos contaminantes son clave en la reactividad atmosférica de la región tropical, especialmente en las estaciones cálidas.



Discusión

- **Actividades humanas en la costa:** En la región costera, las concentraciones de NO_2 son más altas, asociadas con emisiones vehiculares e industriales, principalmente en Lima y Callao. Este patrón es consistente con la literatura que muestra cómo el NO_2 está vinculado a actividades humanas urbanas e industriales, con una marcada disminución durante la cuarentena por COVID-19 en estudios previos.
- **Correlaciones y fuentes comunes:** Se observa una fuerte correlación positiva entre CO y HCHO, lo que sugiere una fuente común, probablemente la quema de biomasa. Las correlaciones entre otros contaminantes, como NO_2 y O_3 , son más débiles, lo que refleja una capacidad predictiva limitada entre estos contaminantes. Además, la correlación en la región amazónica respalda la hipótesis de una fuente común para CO y HCHO, especialmente en zonas de deforestación activa.

■ Implicaciones en Políticas Públicas

- **Fortalecimiento del monitoreo:** Es esencial mejorar el monitoreo de la calidad del aire, especialmente en regiones rurales, utilizando tecnologías como los sensores satelitales (SENTINEL-5P) y plataformas geoespaciales como *Google Earth Engine* para complementar la falta de estaciones terrestres.
- **Sistemas híbridos de vigilancia:** Se debe implementar un sistema híbrido que combine datos satelitales y monitoreo terrestre para una cobertura más equitativa y eficiente en todo el país.
- **Revisión de modelos de ozono:** Los resultados sugieren que los modelos de formación de ozono deben adaptarse al contexto local, ya que centrarse solo en NO_2 no es suficiente para controlar el O_3 en algunas áreas.
- **Enfoque regionalizado y capacidades locales:** Las políticas deben ser diferenciadas por región y estación, y se debe fortalecer el análisis de datos geoespaciales a nivel local para una mejor toma de decisiones.
- **Salud pública y planificación urbana:** Estos hallazgos son cruciales para anticipar riesgos de contaminación y mejorar la planificación sanitaria y urbana, protegiendo la salud pública.

AGRADECIMIENTOS



research@glgconsultae.com

www.glgconsultae.com



gonzalo.rosado@upeu.edu.pe

www.upeu.edu.pe

Más información



<https://casap.science/>



casap@casap.science



Medellín, Colombia

CASAP X

CONGRESO COLOMBIANO Y
CONFERENCIA INTERNACIONAL

DE CALIDAD DE AIRE, CAMBIO CLIMÁTICO Y SALUD PÚBLICA



Más información



<https://casap.science/>



casap@casap.science