




Estimación de $PM_{2.5}$ en la Superficie Usando Datos de Satélites y Otras Fuentes de Información

Parte 2: Estimación de $PM_{2.5}$ a partir de AOD – Metodologías y Conjuntos de Datos Disponibles
Carl Malings (Morgan State University, MSU), Pawan Gupta (NASA GSFC), Aaron van Donkelaar (Washington University in St. Louis), Junhyeon Seo (MSU), Sebastián Diez (Universidad del Desarrollo), Kristina Pistone (NASA ARC/BAERI) & Ana Prados (University of Maryland Baltimore County)

15 de julio 2026



Parte 2 – Formadores

Aaron van Donkelaar

Investigador Asociado
Washington University in St. Louis



Pawan Gupta

Científico Investigador
Goddard Space Flight Center



Junhyeon Seo

Científico Investigador Auxiliar
Morgan State University



Parte 2- Objetivos

Al final de la Parte 2, los participantes podrán:


- Explicar métodos geofísico, híbridos y de aprendizaje automático para inferir $PM_{2.5}$ en la superficie a partir de la AOD de satélite.
- Diferenciar entre productos disponibles para $PM_{2.5}$ en la superficie de la NASA y de Washington University en St. Louis basado en sus metodologías, fortalezas y debilidades.
- Usar herramientas de la NASA y la página web SatPM para acceder a estos productos de datos de $PM_{2.5}$ en la superficie.

Repaso de Conocimiento Adquirido Previamente

- $PM_{2.5}$ es una medida de la concentración de masa in situ de partículas menores a 2.5 micrones.
- La Profundidad Óptica de Aerosoles (también llamada Espesor Óptico de Aerosoles, o AOD por sus siglas en inglés) es una medida óptica de la carga de aerosoles de la columna atmosférica.
- La AOD puede estar bien relacionada con el $PM_{2.5}$ bajo ciertas condiciones, pero la relación se rompe si es que:
 - Los aerosoles son abundantes por encima del nivel del suelo
 - Las partículas de aerosol gruesas son dominantes
 - Los aerosoles absorben agua en condiciones de alta humedad
 - Las condiciones atmosféricas o superficiales impiden cálculos fiables de la AOD del satélite
 - La resolución espacial de los datos AOD no captura la variabilidad local $PM_{2.5}$
 - El momento de las mediciones de $PM_{2.5}$ no coincide con los sobrevuelos del satélite

Cómo Hacer Preguntas

- Para asegurarnos de ver su pregunta, localice los tres puntos (...) en la parte inferior derecha de su ventana de la capacitación.
- Verá una opción de **Slido/Preguntas y respuestas (Q&A)**. También puede ver una pestaña o aplicación independiente de Slido.
- Por favor, coloque todas las preguntas allí y las responderemos durante la sesión de preguntas y respuestas.
- Intentaremos responder todas las preguntas durante la sesión de Q&A después del seminario. Las preguntas restantes se responderán en el documento de preguntas y respuestas, que se publicará en el sitio web de la capacitación aproximadamente una semana después del curso.



Estimación Geofísica e Híbrida de PM_{2.5}

Los monitores terrestres pueden encontrarse lejos de la población

Motiva el uso de AOD para representar $PM_{2.5}$, pero desafía métodos que dependen en gran medida de ubicaciones monitoreadas



Distancia ponderada por población hasta el monitor más cercano


Global	200 km
Norteamérica	20 km
Norte de África/ Oriente Medio	260 km
Asia del sur	70 km
Centro de América Latina	130 km

Population-weighted
Distance to
Nearest Monitor [km]

- >500
- >=250 to <500
- >=100 to <250
- >=50 to <100
- >=10 to <50
- >=1 to <10

2020-2024

Actualizado de: Martin et al., 2019



¿Cómo relacionar AOD con PM_{2.5} sin monitores locales?

De la semana pasada:

$$AOD_{550\text{ nm}} = PM_{2.5} H f(RH) \frac{3 Q_{ext,seco}}{4 \rho r_{eff}}$$

Altura de mezcla (capa límite) → H

Coeficiente de extinción para aerosoles secos → $Q_{ext,seco}$

Función del cambio de dispersión de aerosoles con la humedad relativa → $f(RH)$

Densidad de masa seca de aerosoles → ρ

Radio efectivo de partículas → r_{eff}

Supone:

- Cielos sin nubes
- Capa límite bien mixta
- No hay aerosoles por encima de la capa límite
- Los aerosoles son ópticamente similares a lo largo de toda la columna



¿Y si relajáramos nuestras suposiciones?

Si eliminamos la suposición de que no hay aerosoles por encima de la capa límite y solo consideramos el AOD entre la superficie y una altura cercana a la superficie de Δz :

$$PM_{2.5} = g(RH) \left[\frac{4 \rho_{2.5, \Delta z} r_{eff, 2.5, \Delta z}}{3 Q_{ext, dry, 2.5, \Delta z} \Delta z} \right] \mathcal{F}_{2.5, \Delta z} AOD_{550 nm}$$

entre superficies y Δz y asociado con partículas $< 2.5 \mu m$

Función del cambio de dispersión de aerosoles con la humedad relativa

Fracción de AOD cerca de la superficie

Supone:

- Cielos sin nubes
- Capa límite bien mixta
- No hay aerosoles por encima de la capa límite
- Los aerosoles son ópticamente similares a lo largo de toda la columna



El $PM_{2.5}$ Geofísico depende de la relación basada en teorías y físicamente impulsada entre el AOD total de la columna y $PM_{2.5}$

- Requiere suposiciones locales/representación de parámetros que impulsan la relación
- Independiente de las mediciones locales de $PM_{2.5}$.

$$PM_{2.5} = g(RH) \left[\frac{4 \rho_{2.5,\Delta z} r_{eff,2.5,\Delta z}}{3 Q_{ext,dry,2.5,\Delta z} \Delta z} \right] \mathcal{F}_{2.5,\Delta z} AOD_{550 nm}$$

Factor de Crecimiento, $f(Tipo, RH)$

Densidad, $f(Tipo)$

Radio Efectivo, $f(Tipo)$


Fracción cerca de la Superficie, $f(Perfil Vertical)$

$$PM_{2.5} = \eta \times AOD$$



Coeficiente de Extinción, $f(Tipo)$

Para simplificar, la relación geofísica suele representarse en un solo término escalar, η

Tipo de Aerosol:




Partículas más pequeñas → Partículas más grandes



Los Modelos de Transporte Químico (CTM, por sus siglas en inglés) pueden proporcionar una representación atmosférica espacio-temporalmente completa de la relación AOD a $PM_{2.5}$ (η)



- Una MCC es un modelo informático utilizado para simular la composición atmosférica
- Las MCC combinan las ecuaciones que rigen la física y química atmosférica con la meteorología global y las emisiones
- Las MCC proporcionan una representación completa de la atmósfera
 - **Proporciona toda la información necesaria para representar η**




Los CTMs Capturan los muchos factores que influyen η

η_{Overpass}
($\text{PM}_{2.5}$ / AOD)

July



Las simulaciones representan la variación espaciotemporal de η



Fortalezas:

- Variabilidad espacial/vertical impulsada por emisiones y meteorología locales
- Variabilidad temporal; compensa el paso elevado y el muestreo de satélites.
- Aplicable globalmente sin restricciones adicionales a nivel del suelo

Limitaciones:

- Resolución gruesa (50-100 km)
- Solo son tan buenos sus insumos (por ejemplo, emisiones)
- Desafío para representar eventos individuales
- Intensivo de ejecutar / depende de resultados disponibles de modelos







El $\text{PM}_{2.5}$ Geofísico puede utilizar un η basado en CTMs para relacionar AOD con $\text{PM}_{2.5}$

Fortalezas:

- Captura con éxito características espaciales importantes
- Permite convertir AOD directamente a $\text{PM}_{2.5}$ (multiplicar por η)
- A menudo mejora la correlación con $\text{PM}_{2.5}$ medida en comparación con AOD por sí sola


Desafíos :

- Potencial de sesgo
- Gran cantidad de dispersión con observaciones
- Más efectivo para escalas espaciotemporales mayores
- Difícil identificar la precisión sin validación



El híbrido $PM_{2.5}$ se basa en el $PM_{2.5}$ geofísico utilizando observaciones terrestres

- Los métodos híbridos utilizan entrenamiento estadístico para predecir **el sesgo** entre $PM_{2.5}$ geofísica y observaciones terrestres.
- Utiliza modelos estadísticos para predecir las limitaciones asociadas a las recuperaciones de AOD o la simulación de η .



La Regresión Lineal Múltiple (MLR) puede predecir el sesgo geofísico en $PM_{2.5}$

- La Regresión Lineal Múltiple (MLR, por sus siglas en inglés) proporciona un enfoque intuitivo para predecir el sesgo geofísico con variables independientes



Diagrama de la ecuación de Regresión Lineal Múltiple:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon$$

Etiquetas:

- Variable Dependiente (resultado): Y
- Intercept: β_0
- Coeficientes Predictores: $\beta_1, \beta_2, \dots, \beta_n$
- Variables Independientes (Predictores): $X_1, X_2, \dots, X_n$
- Término de Error: ε

- La MLR extiende la regresión lineal simple (es decir, un predictor)
 - las pendientes de cada variable independiente, X_n , se representan por β_n
 - β_n puede considerarse como la respuesta lineal en Y a los cambios en el predictor X_n .



La Regresión Geográficamente Ponderada (GWR) permite coeficientes predictores espacialmente variables


Diagram illustrating the GWR regression equation:

$$Y_{i,j} = \beta_{0,i,j} + \beta_{1,i,j}X_{1,i,j} + \beta_{2,i,j}X_{2,i,j} + \dots + \beta_{n,i,j}X_{n,i,j} + \varepsilon_{i,j}$$

Labels for the equation components:

- Variable Dependiente (resultado): $Y_{i,j}$
- Intercepto: $\beta_{0,i,j}$
- Variables Independientes (Predictores): $X_{1,i,j}, X_{2,i,j}, \dots, X_{n,i,j}$
- Coeficientes Predictores: $\beta_{1,i,j}, \beta_{2,i,j}, \dots, \beta_{n,i,j}$
- Término de Error: $\varepsilon_{i,j}$
- Valor en la ubicación i,j : Indicated by a blue circle around $X_{1,i,j}$.

- Variables predictoras individuales no espacialmente constantes
- Se aplica un mapa de coeficientes predictores al mapa de variables predictoras
- La MLR se calibra en ubicaciones discretas de una red global
 - Los sitios están ponderados por las distancias a cada monitor
 - Se excluyen los sitios que superan un umbral de distancia
 - La cuadrícula puede ser constante o variar según la densidad del sitio de entrenamiento



Cada + representa una ubicación discreta considerada para un GWR




Los predictores efectivos en GWR se relacionan con incertidumbres en AOD y η

Los predictores comunes relacionados con la incertidumbre del AOD o η incluyen:

Tipo de Aerosol:



Partículas más pequeñas → Partículas más grandes



Composición

Representativa de diferentes fuentes de emisiones, perfiles verticales y factores de crecimiento

Meteorología

Posibles impactos en el perfil vertical, formación de aerosoles, emisiones

Tipo de terreno

Posibles impactos en el cálculo de AOD y emisiones

Elevación/Cambios de esta

Posibles impactos en el perfil vertical y en las características de alta resolución (CTM subcuadricular)



Los conocimientos predictores se combinan para la predicción del sesgo geofísico total

$$(\text{GM PM}_{2.5} - \text{SAT PM}_{2.5})_{i,j} = \beta_{0,i,j} + \sum \beta_{\text{SPEC}_{i,j,k}} \text{SPEC}_{i,j,k} + \sum \beta_{\text{MET}_{i,j,k}} \text{factures} + \beta_{\text{ELEV}_{i,j}} \text{ELEV}_{i,j} + \beta_{\text{LT}_{i,j,k}} \text{LT}_{i,j,k}$$

Diferencia entre $\text{PM}_{2.5}$
Geofísico y de Monitores



Composición
Simulada

Parámetros
Meteorológicos

Parámetros
de Elevación

Parámetros
de Tipo de
terreno

- Captura características de sesgo observadas
- Predice características en lugares no observados





Los predictores individuales ofrecen perspectivas y direcciones únicas

Nitrato:

- β relativamente constante sobre regiones de impacto
- Explica la sobreestimación geofísica regional
- ¿Efecto químico/emisión?



Nitrate



Porcentaje urbano:

- Pendiente clara este-oeste en β
- Impacta el sesgo geofísico a escala fina
- Efecto η en la resolución/ cálculo de AOD?

Percent Urban






El PM_{2.5} híbrido a nivel global refina el PM_{2.5} puramente geofísico

Fortalezas:

- Mantiene la aplicabilidad global de los métodos geofísicos
- Incluye restricciones a nivel del suelo
- Mejora el PM_{2.5} geofísico

Limitaciones:

- Requiere observaciones desde tierra
- La configuración efectiva del modelo es complicada
- Marco del modelo
- Selección de variables predictoras
- Los modelos deben ser aplicables a nivel global
- Evita el sobreajuste
- ¡La validación cruzada adecuada es clave!




La Validación Cruzada (CV) permite una evaluación independiente de la incertidumbre

La selección del método debe equilibrar complejidad, precisión y representación, basándose en las propiedades del sitio de observación; debe mantener la independencia del conjunto de datos CV

Validación cruzada aleatoria k-fold

- Entrenar modelos separados k veces (por ejemplo, $k=10$), reteniendo aleatoriamente los sitios de datos del entrenamiento para su posterior validación
- Implementación sencilla
- Los sitios de datos agrupados o relacionados provocarán una sobrerrepresentación de la precisión
 - ¡Los sitios colocados no son independientes!




La CV con búfer espacial reduce el impacto de la autocorrelación espacial

La selección del método debe equilibrar la complejidad, precisión, y representación, basándose en las propiedades del sitio de observación; debe mantener la independencia del conjunto de datos CV

Validación cruzada con búfer espacial

- Añade un búfer espacial para aumentar la independencia de los sitios de CV
- Entrenar modelos separados, reteniendo datos del entrenamiento para validación posterior, además de excluir monitores adicionales dentro del búfer espacial del entrenamiento
- Múltiples implementaciones:
 - Búfer Deja uno fuera (BLOO)
 - Retiene un sitio a la vez
 - Efectivo, pero computacionalmente costoso
 - Buffered Leave Cluster Out (BLeCO) / Buffered Leave Isolated Sites and Cluster Out (BLISCO)
 - Excluye grupos de sitios más su búfer
 - Eficiencia computacional mejorada




La CV de retención temporal reduce el impacto de la autocorrelación temporal

La selección del método debe equilibrar complejidad, precisión y representación, basándose en las propiedades del sitio de observación; debe mantener la independencia del conjunto de datos CV

Exclusión temporal


- Para casos específicos donde se aplican modelos a lo largo del tiempo
- Informativa para incertidumbres temporales (es decir, series temporales)
- Excluye todas las observaciones tomadas durante un periodo especificado para su posterior validación
- Puede combinarse con análisis con búfer espacial



Resumen - Estimación Geofísica e Híbrida de $PM_{2.5}$

- Los métodos geofísicos para estimar $PM_{2.5}$ a partir de observaciones satelitales de AOD evitan el uso de monitores terrestres mediante una relación basada en teoría y basada en la física, entre AOD total de columna y $PM_{2.5}$.
- Los Modelos de Transporte Químico (CTM, por sus siglas en inglés) pueden utilizarse para proporcionar globalmente los parámetros necesarios que permitan métodos geofísicos.
- Los métodos híbridos se basan en métodos geofísicos utilizando observaciones de $PM_{2.5}$ terrestres para comprender, predecir y corregir sesgos en los valores geofísicos mediante un marco estadístico.
- Los marcos estadísticos requieren una validación cruzada efectiva para una representación precisa de la incertidumbre y, por lo tanto, deben garantizar una fuerte independencia de los puntos de validación.





$\text{SatPM}_{2.5}$ en ACAG de Washington University en St. Louis




Atmospheric
Composition
Analysis
Group



WashU

SatPM_{2.5} de ACAG proporciona acceso público a un conjunto de datos de PM_{2.5} global




SatPM_{2.5} proporciona un conjunto de datos de PM_{2.5} global, global y a largo plazo que es:

- Restringido en cuanto a observaciones mediante AOD satelital y monitores terrestres
- Basado en un marco híbrido-geofísico
- Mensual, 1998-2024 (actualizado anualmente)
- Alta resolución (cuadrícula $0,01^\circ \times 0,01^\circ$)
- Disponible públicamente en: <http://satpm.org>




**Atmospheric
Composition
Analysis
Group**



Diferentes cálculos de AOD están diseñados para distintas condiciones

Las diferencias son resultado de la instrumentación, la metodología y el muestreo



Mean Terra AOD for April 2014






AERONET permite una evaluación consistente de la incertidumbre de AOD



AERONET AOD:

- Mundial
- Preciso
- A largo plazo
- Permite la evaluación directa de los productos satelitales

➤ **¿Cómo ampliar globalmente las comparaciones específicas de ubicación fuera de las ubicaciones/horarios de la red?**





La incertidumbre local puede inferirse usando ubicaciones con condiciones similares

Realice comparaciones AOD usando todos los sitios AERONET según el/la:


- Cálculo
- Mes
- Tipo de terreno
- Índice de Vegetación Diferenciada Normalizada (NDVI, en inglés)
- Proximidad al lugar de interés

➤ **Recombinación basada en las condiciones locales**

Definición continua y consistente de error global



Evaluación global: Utilizar cada conjunto de datos AOD en su mejor versión








Diferentes fuentes de AOD combinadas usando un promedio ponderado basado en incertidumbres locales:

- NRMSD
- Sesgo (es decir, pendiente)
- Densidad de datos (número de observaciones)




$$AOD = \frac{\sum_{n=1}^N \frac{1}{NRMSD_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2 \times AOD_n}{\sum_{n=1}^N \frac{1}{NRMSD_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2}$$

Evaluación global: Utilizar cada conjunto de datos AOD en su mejor versión




Los pesos resultantes para cada conjunto de datos son intuitivos.






➤ **Combinar todas las fuentes AOD ponderadas por $NRMSD^{-1}$, corrección de sesgo $^{-1}$, densidad de datos:**

$$AOD = \frac{\sum_{n=1}^N \frac{1}{NRMSD_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2 \times AOD_n}{\sum_{n=1}^N \frac{1}{NRMSD_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2}$$

Evaluación global: Utilizar cada conjunto de datos AOD en su mejor versión



El AOD simulado puede ayudar sobre condiciones no calculadas.




➤ Combinar todas las fuentes AOD ponderadas por $NRMSD^{-1}$, corrección de sesgo $^{-1}$, densidad de datos:

$$AOD = \frac{\sum_{n=1}^N \frac{1}{NRMSD_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2 \times AOD_n}{\sum_{n=1}^N \frac{1}{NRMSD_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2}$$

Error Sim.


-
- Emisiones
 - Química
 - Óptica
 - Meteorología
- Ponderación AERONET**
-
- comparación por**
- Especies
 - Proximidad
 - Elevación
 - Similitud

Evaluación global: Utilizar cada conjunto de datos AOD en su mejor versión

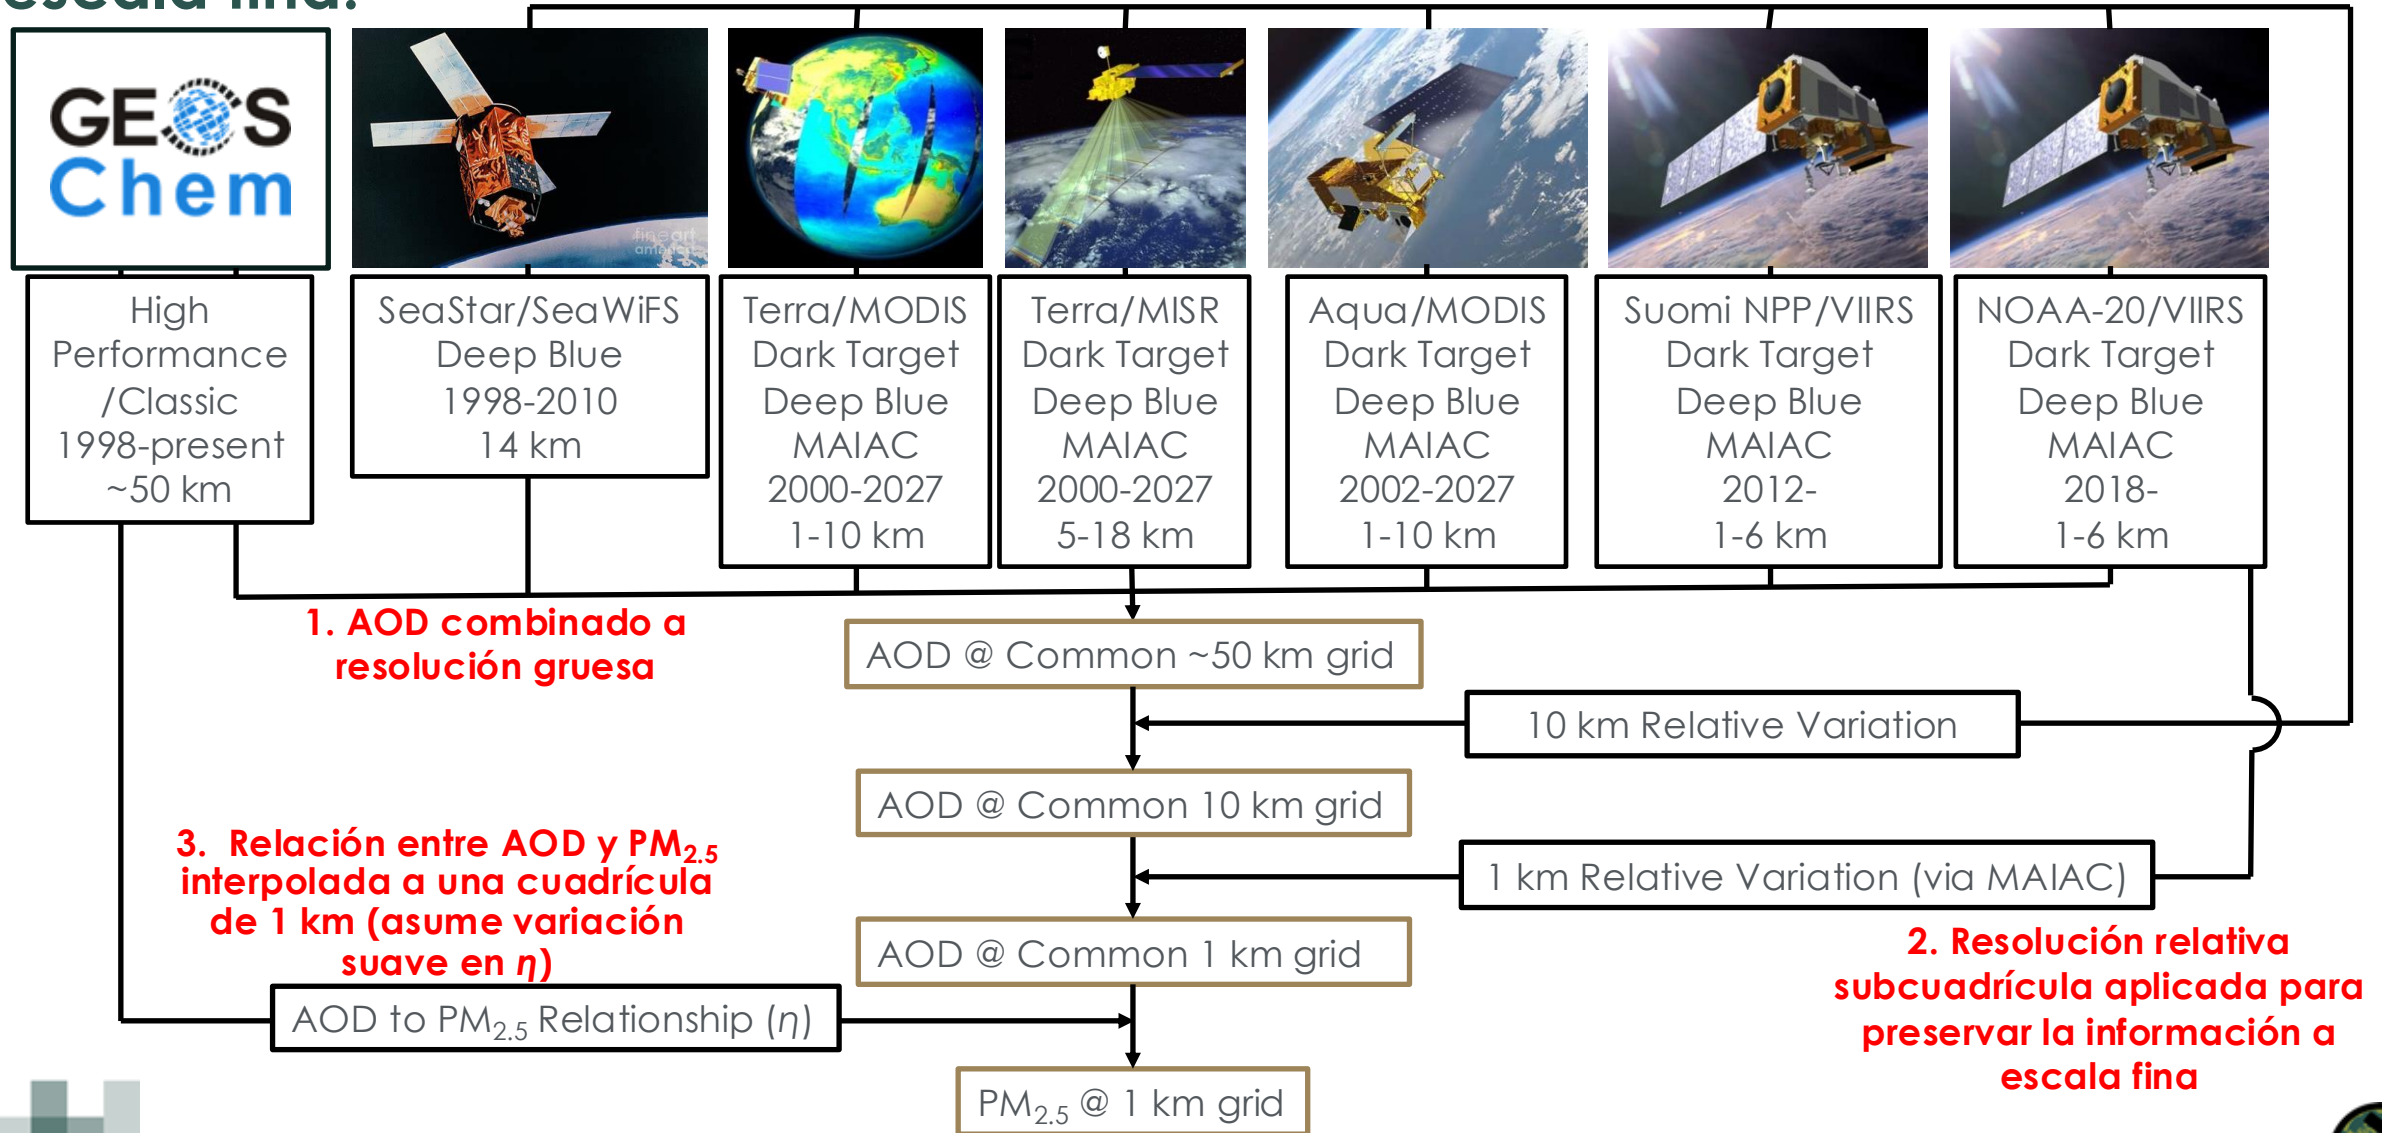


➤ Combinar todas las fuentes AOD ponderadas por NRMSD^{-1} , corrección de sesgo $^{-1}$, densidad de datos:

$$AOD = \frac{\sum_{n=1}^N \frac{1}{\text{NRMSD}_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2 \times AOD_n}{\sum_{n=1}^N \frac{1}{\text{NRMSD}_n} \times \left[\frac{\Delta AOD_{adj,n}}{AOD_n} \right]^{-1} \times N_{obs,n}^2}$$




Los conjuntos de datos AOD se combinan para beneficiarse de promedios multifuente y preservar características a escala fina.



ACAG en WashU orgullosamente forma parte de la comunidad GEOS-Chem.

Misión de la Comunidad GEOS-Chem: Avanzar en la comprensión de las influencias humanas y naturales en el medio ambiente mediante un modelo global integral de la composición atmosférica de vanguardia y fácilmente accesible.



La 11ª reunión internacional de GEOS-Chem en WashU en junio de 2024 contó con 278 inscritos de 96 instituciones y 22 países.

ACAG SatPM_{2.5}

Multi-Source,
Combined AOD

Geophysical PM_{2.5}

Hybrid-Geophysical
Bias Prediction



Hybrid PM_{2.5}




La relación geofísica (η) se produce usando el CTM de GEOS-Chem

Características relevantes del CTM de GEOS-Chem para SatPM_{2.5}:

- De código abierto, impulsado por la comunidad
- Modelo detallado de aerosoles oxidantes
 - Sistema Sulfato-Nitrato-Amonio
 - Carbonáceos (primarios y secundarios)
 - Polvo Mineral (natural y antrópico)
 - Sal marina
- Las emisiones incluyen:
 - Aerosoles de polvo impulsados por factores meteorológicos, VOC biogénicos, NO_x de rayos y del suelo, y aerosol de sal marina
 - Emisiones antropogénicas de alta resolución a través de los inventarios regionales y CEDS v2
 - Incendios abiertos – GFED4.1, GFAS, etc. que varían temporalmente.
- Meteorología asimilada (MERRA2, GEOS-IT etc.)
- Resoluciones típicas de ~50×50 km²



El PM_{2.5} híbrido global requiere observaciones globales desde tierra




Actualmente incluimos PM_{2.5} terrestre de aproximadamente 15.000 sitios, utilizando observaciones recolectadas de:

- EE.UU. (EPA/AQS)
- Canadá (NAPS)
- Europa (Airbase)
- Australia (NT,Q,NSW)
- Taiwán (EPA Taiwanesa /OpenAQ)
- Global (GBD/WHO, OpenAQ)
- China (EPA China)
- India (CPCB)
- Corea del Sur(MoE)
- Omán (EA)
- Reino de Jordania (MoE)
- Argentina (ACUMAR)
- Brasil (IEMA)
- Chile (SINCA)
- Colombia (SISAIRE)
- Ecuador (REMMAQ)
- Uruguay (Montevideo)




Las observaciones terrestres no son completas temporalmente.


Hay que representar los periodos de tiempo perdidos para que las series temporales sean consistentes.



- Inferir observaciones terrestres utilizando:
 - Monitores terrestres
 - Simulaciones
 - $PM_{2.5}$ geofísico.
- Combinar los valores inferidos usando la incertidumbre observada
- Una serie temporal completa temporalmente basada en tierra limita el impacto de los cambios de cobertura en la serie temporal SatPM2.5



Includiendo otros Monitores $PM_{2.5}$ Observado [$\mu g/m^3$] Sin Info. de Monitores



van Donkelaar et al., ES&T, 2021




ACAG Hybrid PM2.5 utiliza una Red Neuronal Convolucional (CNN, por sus siglas en inglés).


- Una CNN es un algoritmo de aprendizaje automático de vanguardia.
 - Especialmente diseñado para identificar y aprender a partir de imágenes.
 - Altamente efectivo para tareas espaciales, como la relación del sesgo geofísico PM2.5 con los predictores circundantes.
- Entrenado por separado cada mes
 - Capturar la variabilidad temporal en las relaciones entre predictores y sesgo
- También está disponible la Regresión Geográficamente Ponderada (GWR), como versión V5.

CNN Predictor Variables

- **Productos satelitales**
 - AOD
 - $PM_{2.5}$ Geofísico
- **Emisiones**
 - Antrópico
 - Carbono orgánico
 - Carbono negro
 - Polvo
 - Sal Marina
- **Salidas del CTM**
 - $PM_{2.5}$
 - Componentes
 - η
 - Incertidumbre de η
- **Meteorología**
 - PBLH
 - Humedad relativa
 - Temperatura (2 m)
 - Velocidad del viento V (10 m)
 - Velocidad del viento U (10 m)




- **Ubicaciones de los sitios**
- **Geología**
 - Tipo de terreno
 - Elevación





Los predictores geofísicos y basados en procesos alejan el acuerdo de las restricciones terrestres.

Demstrado tanto por validación cruzada con búfer espacial como por análisis SHapley Additive ExPlanations (SHAP)

Los predictores basados en procesos son aquellos que incluyen la respuesta atmosférica a factores físicos y químicos, como concentraciones simuladas de componentes y η .



Análisis SHAP: Las variables están ordenadas por importancia



- Geo indica la geofísica a priori restringida por la salida de GEOS-Chem
- GC indica GEOS-Chem






SatPM2.5 ofrece una representación global de alta calidad en PM_{2.5}.

- SatPM2.5 V6. GL.03 refina el PM_{2.5} geofísico en la superficie utilizando el modelo CNN optimizado de ACAG.
- Se evalúa utilizando los estándares de validación cruzada más altos – utilizando búfer temporal y espacial
- SatPM2.5 es especialmente adecuado para aplicaciones que requieren:
 - Alta resolución espacial
 - Cobertura temporal consistente y a largo plazo
 - Consistencia lejos de las restricciones a nivel del suelo



**Atmospheric
Composition
Analysis
Group**




Resumen – SatPM2.5 @ ACAG Washington University en St. Louis

En esta sección, nos hemos centrado en el conjunto de datos SatPM2.5 de ACAG.

Este conjunto de datos:

- Se basa en el método Geofísico-Híbrido.
- Combina múltiples productos de AOD, utilizando AERONET para identificar qué recuperaciones son más efectivas bajo condiciones, ubicaciones y momentos específicos.
- Incorpora y mantiene activamente una base de datos de ~15,000 monitores terrestres.
 - Explica las variaciones en la cobertura temporal de estas observaciones terrestres.
- Utiliza una Red Neuronal Convolutiva (CNN, por sus siglas en inglés) para comprender, predecir y corregir el sesgo geofísico. Limitaciones basadas en procesos esenciales para mantener la calidad lejos de los monitores.
- Se centra en la consistencia a largo plazo a lo largo de toda la serie temporal y alejándose de las restricciones terrestres.
- Está disponible de forma gratuita y pública.





Acceso a productos de datos SatPM2.5 – Demo de la página web

<http://satpm.org>

Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5

The screenshot shows the SatPM website interface. At the top, the browser address bar displays "Home | satpm.org" and "www.satpm.org". The website header includes the ACAG logo and navigation links: Home, Data Access, Tools & Examples, Archive, Publications, and Support Team. The main content area is titled "Satellite-Derived PM_{2.5}" and describes the data's purpose for air quality assessment. It lists three key features: global coverage, multi-year records, and tailored product versions. Below this, there are two global maps of PM_{2.5} concentrations. The left map shows a comparison between V6 GL03 satellite data and ground-based observations (Obs) with an R² value of 0.80. The right map shows 2024 PM_{2.5} concentrations. A color scale at the bottom of the maps ranges from 3 to 200 µg/m³. The text below the maps explains that SatPM combines satellite retrievals, process-based simulations, and ground-based measurements. It details the use of various satellite instruments (MODIS, SeaWiFS, VIIRS) and retrieval algorithms (Dark Target, Deep Blue, MAIAC) in conjunction with the GEOS-Chem model and ground-based observations (SPARTAN, WHO Ambient Air quality database, OpenAQ) to refine estimates. A triangular diagram on the right illustrates the integration of Satellite, Simulation, and Monitors data for PM_{2.5}. The footer includes the SatPM logo, the text "Satellite-Derived Particulate Matter", and a link to join the mailing list for updates on data products and events.

Home | satpm.org

www.satpm.org

SatPM

Home Data Access Tools & Examples Archive Publications Support Team

Satellite-Derived PM_{2.5}

Data on the distribution of fine particulate matter (PM_{2.5}) in outdoor air are needed to support air quality assessment, research, and management. Rigorously validated open-access satellite-derived PM_{2.5} datasets offer:

- Global coverage of fine particulate matter concentrations
- Multi-year records for trend analysis (1998-present)
- Multiple product versions tailored to regional and compositional studies

V6 GL03 (µg/m³)

Obs (µg/m³)

R² = 0.80

2024 PM_{2.5} (µg/m³)

3 5 10 20 50 100 200

SatPM global and regional PM_{2.5} concentrations combine the observational constraint of satellite retrievals, the coverage and insight of process-based simulations and data-driven algorithms, and the accuracy of ground-based measurements.

Aerosol observed throughout the atmospheric column from multiple satellite-based instruments ([MODIS/Terra](#), [MODIS/Aqua](#), [MISR/Terra](#), [SeaWiFS/SeaStar](#), [VIIRS/SNPP](#) and [VIIRS/NOAA20](#)) and their respective retrievals ([Dark Target](#), [Deep Blue](#), [MAIAC](#)) are related to near surface PM_{2.5} concentrations using the [GEOS-Chem](#) chemical transport model, where GEOS-Chem provides the spatially and temporally varying relationship between aerosol optical depth and PM_{2.5}. Targeted observations (e.g., [SPARTAN](#)) are used for process-level evaluation of algorithms. A collection of ground-based observations from around the world (e.g., [WHO Ambient Air quality database](#), [OpenAQ](#), national regulatory networks, SPARTAN) are then used to refine these initial estimates using advanced statistical fusion and deep-learning techniques.

Satellite

PM_{2.5}

Simulation Monitors

SatPM

Satellite-Derived Particulate Matter


Join our mailing list for updates on data products and events

Email *



Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5

Enlaces de las pestañas
de acceso a datos a los
últimos conjuntos de
datos SatPM2.5



Home | satpm.org

50%

Search

SatPM


Home Data Access Tools & Examples Archive Publications Support Team

SatPM V6.GL.03
SatPM V6.NA.01
SatPM V5.GL.06

Satellite-Derived PM_{2.5}

Data on the distribution of fine particulate matter (PM_{2.5}) in outdoor air are needed to support air quality assessment, research, and management. Rigorously validated open-access satellite-derived PM_{2.5} datasets offer:


- Global coverage of fine particulate matter concentrations
- Multi-year records for trend analysis (1998-present)
- Multiple product versions tailored to regional and compositional studies



2024 PM_{2.5} (µg/m³)

SatPM global and regional PM_{2.5} concentrations combine the observational constraint of satellite retrievals, the coverage and insight of process-based simulations and data-driven algorithms, and the accuracy of ground-based measurements.

Aerosol observed throughout the atmospheric column from multiple satellite-based instruments ([MODIS/Terra](#), [MODIS/Aqua](#), [MISR/Terra](#), [SeaWiFS/SeaStar](#), [VIIRS/SNPP](#), and [VIIRS/NOAA20](#)) and their respective retrievals ([Dark Target](#), [Deep Blue](#), [MAIAC](#)) are related to near surface PM_{2.5} concentrations using the [GEOS-Chem](#) chemical transport model, where GEOS-Chem provides the spatially and temporally varying relationship between aerosol optical depth and PM_{2.5}. Targeted observations (e.g., [SPARTAN](#)) are used for process-level evaluation of algorithms. A collection of ground-based observations from around the world (e.g., [WHO Ambient Air quality database](#), [OpenAQ](#), national regulatory networks, SPARTAN) are then used to refine these initial estimates using advanced statistical fusion and deep-learning techniques.



Satellite
PM_{2.5}
Simulation Monitors

SatPM
Satellite-Derived Particulate Matter

Join our mailing list for updates on data products and events

Email *

www.satpm.org/data-access

Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5

Enlaces de las pestañas
de acceso a datos a los
últimos conjuntos de
datos SatPM2.5

**Cada página individual
proporciona detalles de cada
versión**

SatPM V6.GL.03 | satpm.org

www.satpm.org/v6-gl-03

50%

Search

Home Data Access Tools & Examples Archive Publications Support Team

SatPM V6.GL.03

This version is recommended for users interested in our most state-of-the-science global algorithm, and is available for 1998-2024

We estimate annual and monthly ground-level fine particulate matter ($PM_{2.5}$) for 1998-2024 by combining Aerosol Optical Depth (AOD) retrievals (Dark Target, Deep Blue, MAIAC) that make use of observations from numerous satellite-based NASA instruments (MODIS/Terra, MODIS/Aqua, MISR/Terra, SeaWiFS/SeaStar, VIIRS/SNPP, and VIIRS/NOAA20) with the GEOS-Chem chemical transport model, and subsequently calibrating to global ground-based observations using a residual Convolutional Neural Network (CNN), as detailed in the below reference for SatPM V6.GL.01. SatPM V6.GL.03 follows the methodology of V6.GL.01 and V6.GL.02.04, but updates the ground-based observations used to calibrate the geophysical $PM_{2.5}$ estimates for the entire time series, extends temporal coverage through 1998 – 2024, and includes additional MAIAC AOD retrievals using the VIIRS instruments onboard the Suomi NPP and NOAA-20 satellites. Also, the GEOS-Chem information (and the geophysical $PM_{2.5}$) includes the latest updates on dust size and distribution, as described in Zhang et al. [2025].

Reference:

Shen, S. Li, C. van Donkelaar, A. Jacobs, N. Wang, C. Martin, R. V.: Enhancing Global Estimation of Fine Particulate Matter Concentrations by Including Geophysical a Prior Information in Deep Learning. (2024) ACS ES&T Air. DOI: 10.1021/acsestair.3c00054 [Link]

Scientific Datasets:

Annual and monthly datasets are provided in NetCDF [.nc] format. Gridded files use the WGS84 projection.

Note that these estimates are primarily intended to aid in large-scale studies. Annual and coarse-resolution averages correspond to a simple mean of within-grid values. Gridded datasets are provided to allow users to agglomerate data as best meets their particular needs. High-resolution ($0.01^\circ \times 0.01^\circ$) datasets are gridded at the finest resolution of the information sources that were incorporated, but are unlikely to fully resolve $PM_{2.5}$ gradients at the gridded resolution due to the influence of information sources at coarser resolution.

Annual and monthly mean $PM_{2.5}$ [$\mu g/m^3$] at $0.01^\circ \times 0.01^\circ$:
<https://wustl.box.com/v/V6GL03-FineResolution>

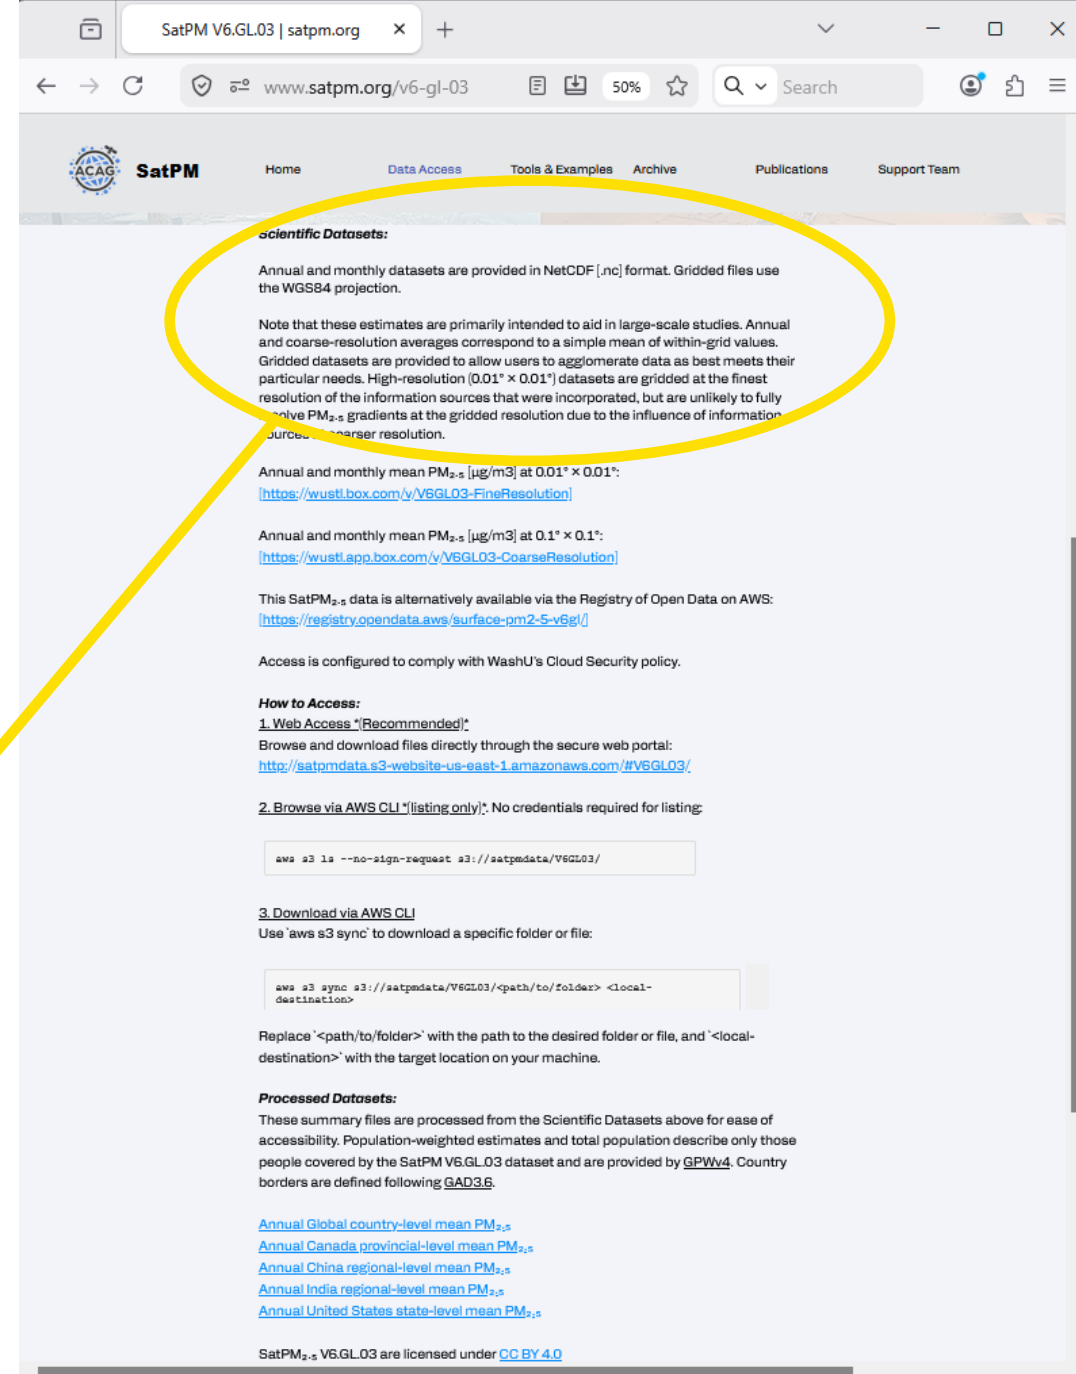


Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5


Enlaces de las pestañas
de acceso a datos a los
últimos conjuntos de
datos SatPM2.5

Cada página individual
proporciona detalles de cada
versión

Incluye Conjunto de
Datos/Instrucciones de Acceso

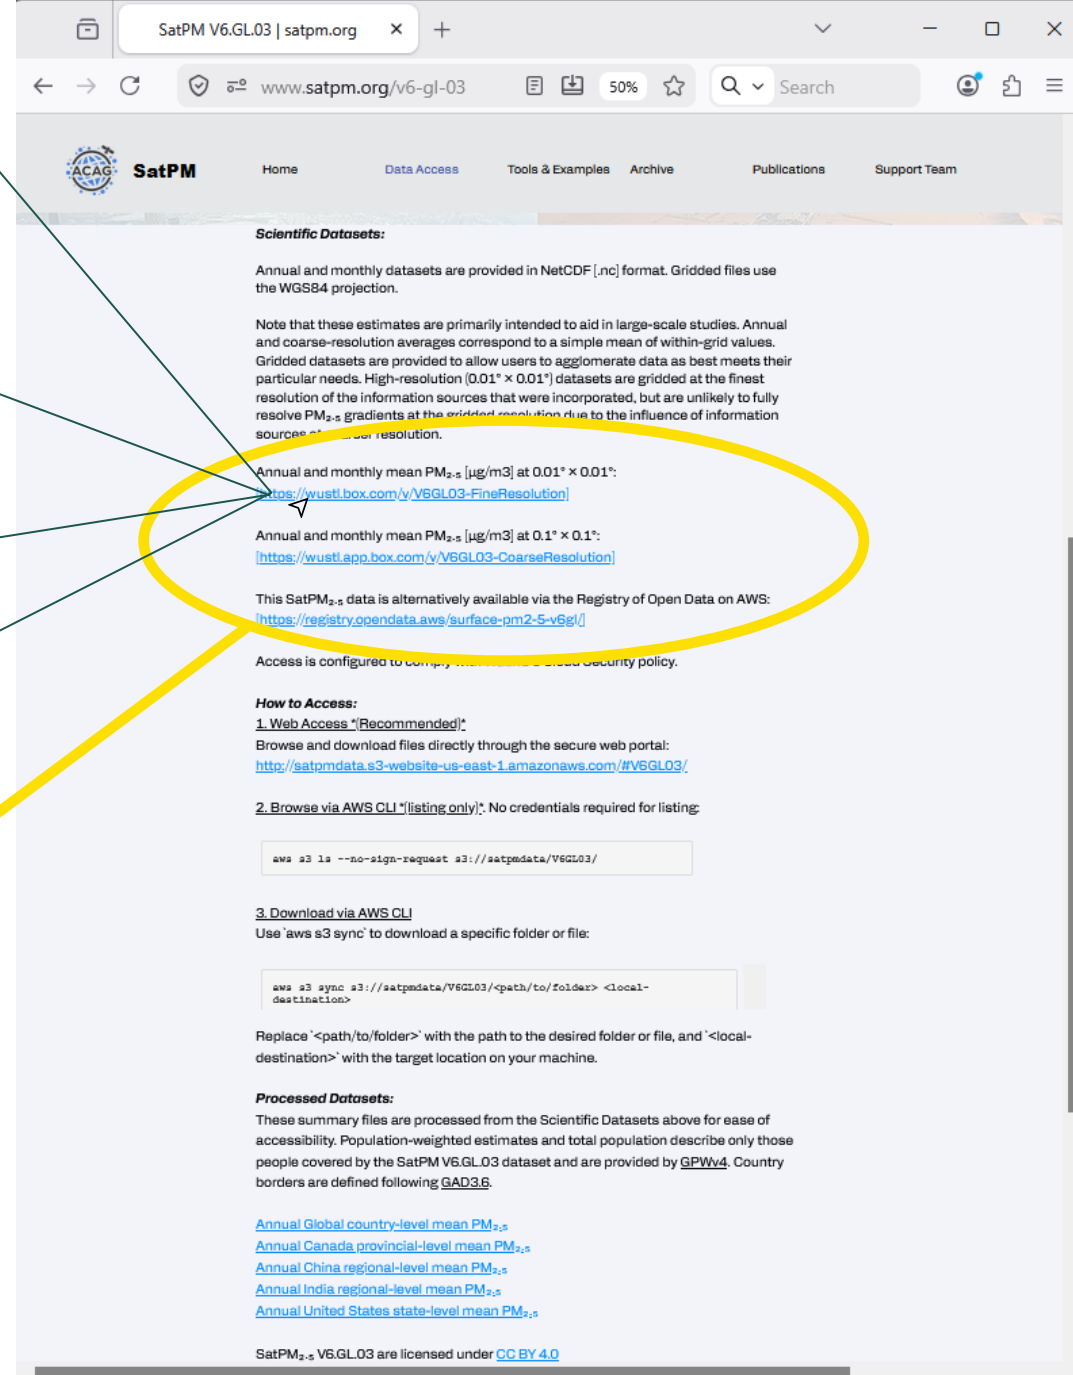


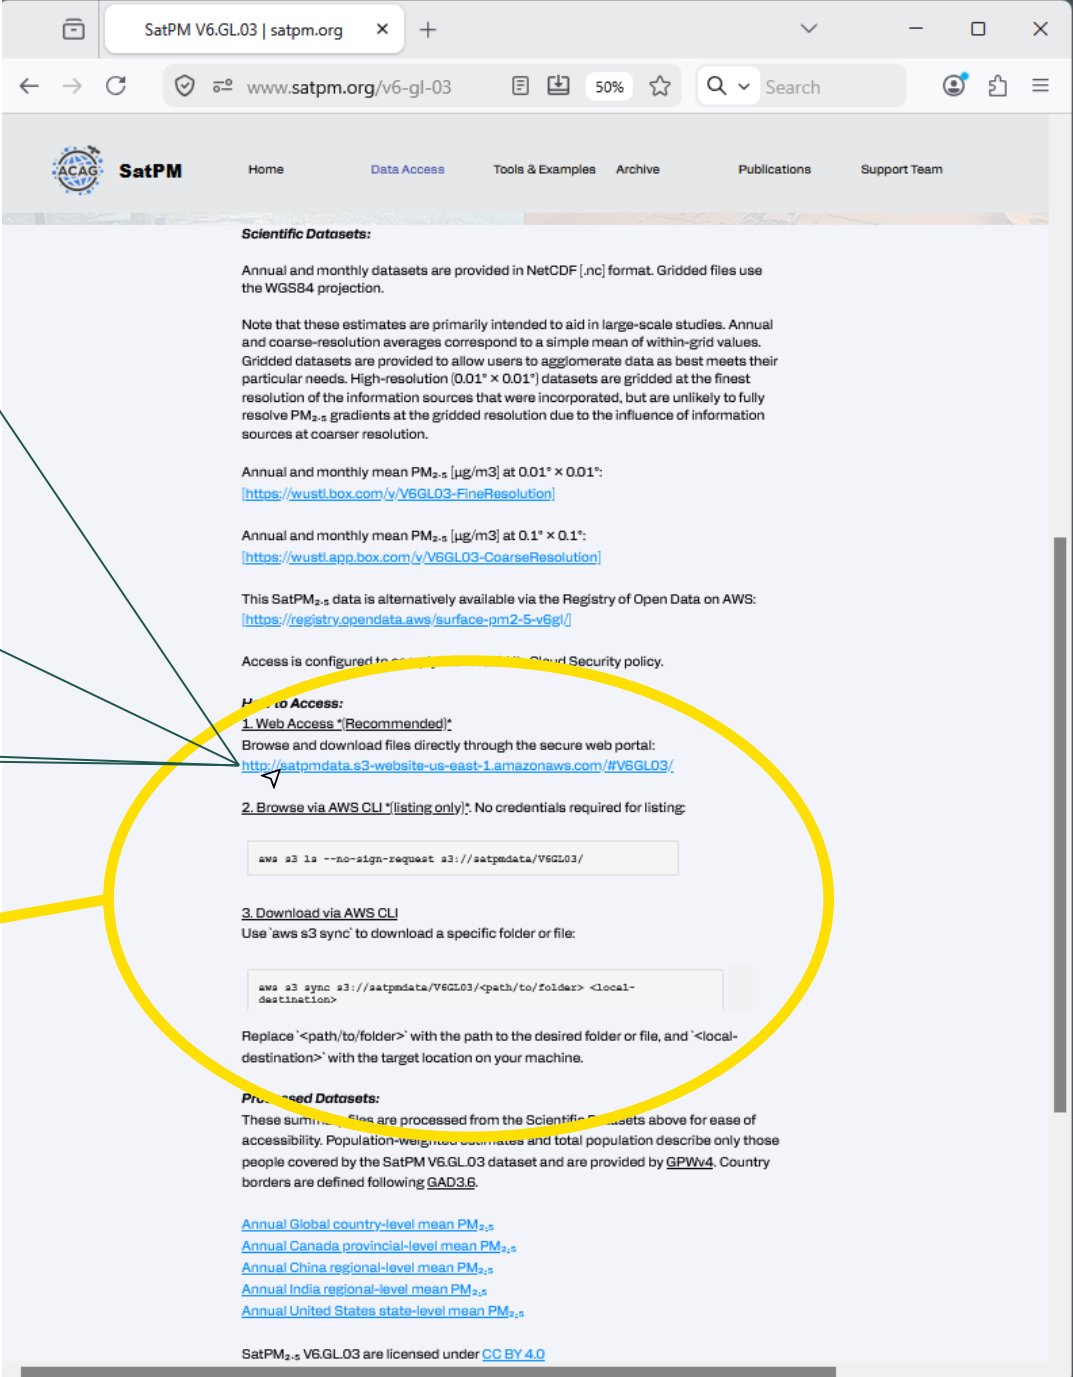

(www.satpm.org) Proporciona acceso a las últimas versiones de los datos y detalles de cada versión



versión

Incluye Conjunto de Datos/Instrucciones de Acceso mediante Carpetas





Incluye Conjunto de
Datos/Instrucciones de Acceso
mediante Carpetas
y a través del Registro de Datos
Abiertos AWS



Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5

Enlaces de las pestañas
de acceso a datos a los
últimos conjuntos de
datos SatPM2.5

Cada página individual
proporciona detalles de cada
versión

Incluye Conjunto de
Datos/Instrucciones de Acceso
mediante Carpetas
y a través del Registro de Datos
Abiertos AWS

Los conjuntos de datos
procesados proporcionan
resúmenes simplificados

The screenshot shows the SatPM V6.GL.03 website. The header includes the ACAG SatPM logo and navigation links: Home, Data Access, Tools & Examples, Archive, Publications, and Support Team. The main content area provides information about data formats (NetCDF), resolution, and access methods. A yellow circle highlights the 'Processed Datasets' section, which lists summary files for various regions. The footer mentions the license (CC-BY 4.0).

Annual and monthly datasets are provided in NetCDF [nc] format. Gridded files use the WGS84 projection.

Note that these estimates are primarily intended to aid in large-scale studies. Annual and coarse-resolution averages correspond to a simple mean of within-grid values. Gridded datasets are provided to allow users to aggregate data as best meets their particular needs. High-resolution ($0.01^\circ \times 0.01^\circ$) datasets are gridded at the finest resolution of the information sources that were incorporated, but are unlikely to fully resolve $PM_{2.5}$ gradients at the gridded resolution due to the influence of information sources at coarser resolution.

Annual and monthly mean $PM_{2.5}$ [$\mu\text{g}/\text{m}^3$] at $0.01^\circ \times 0.01^\circ$:
<https://wustl.box.com/y/V6GL03-FineResolution>

Annual and monthly mean $PM_{2.5}$ [$\mu\text{g}/\text{m}^3$] at $0.1^\circ \times 0.1^\circ$:
<https://wustl.app.box.com/y/V6GL03-CoarseResolution>

This SatPM_{2.5} data is alternatively available via the Registry of Open Data on AWS:
<https://registry.opendata.aws/surface-pm2-5-v6gl/>

Access is configured to comply with WashU's Cloud Security policy.

How to Access:

1. Web Access *(Recommended)*:
Browse and download files directly through the secure web portal:
<http://satpmdata.s3-website-us-east-1.amazonaws.com/#V6GL03/>

2. Browse via AWS CLI *(listing only)*: No credentials required for listing:

```
aws s3 ls --no-sign-request s3://satpmdata/V6GL03/
```

3. Download via AWS CLI
Use 'aws s3 sync' to download a specific folder or file:

```
aws s3 sync s3://satpmdata/V6GL03/<path/to/folder> <local-destination>
```

Replace '<path/to/folder>' with the path to the desired folder or file, and '<local-destination>' with the local destination on your system.

Processed Datasets:
These summary files are processed from the Scientific Datasets above for ease of accessibility. Population-weighted estimates and total population describe only those people covered by the SatPM V6.GL.03 dataset and are provided by GPWv4. Country borders are defined following GAD3.6.

[Annual Global country-level mean \$PM_{2.5}\$](#)
[Annual Canada provincial-level mean \$PM_{2.5}\$](#)
[Annual China regional-level mean \$PM_{2.5}\$](#)
[Annual India regional-level mean \$PM_{2.5}\$](#)
[Annual United States state-level mean \$PM_{2.5}\$](#)

SatPM_{2.5} V6.GL.03 are licensed under [CC-BY 4.0](#)



Region	Year	Population-Weighted Mean PM2.5 [µg/m3]	Geographic Coverage [%]	Total Population [million people]	% pop >= 5 µg/m3	% pop >= 10 µg/m3	% pop >= 15 µg/m3	% pop >= 25 µg/m3	% pop >= 30 µg/m3	% pop >= 35 µg/m3	% pop >= 40 µg/m3	% pop >= 45 µg/m3	% pop >= 50 µg/m3	% pop >= 55 µg/m3	% pop >= 60 µg/m3
1081 Chile	2024	18.9	18.8	100	100	18.738	100	96.7	73	29.9	1.7	0.8	0.4	0.1	0
1082 China	1998	26.8	19.7	100	100	1266.692	100	99.5	97.4	64.4	45.1	23.2	6.7	0.9	0.4
1083 China	1999	27.1	18.5	100	100	1266.692	100	99.7	96.1	59.2	38.8	15.2	3.1	0.5	0.3
1084 China	2000	33.2	21.9	100	100	1266.692	100	99.9	98.8	77.1	57.1	42.2	23.4	12.8	5.2
1085 China	2001	35.1	23.4	100	100	1273.709	100	99.9	98.7	84	65.6	46.8	32.1	17	6.9
1086 China	2002	37.7	23.8	100	100	1280.846	100	99.9	98.9	86.5	68.3	55.1	43.6	29.5	15.7
1087 China	2003	42.3	26.6	100	100	1287.923	100	99.8	99.3	93.3	78.9	64.5	53.1	41.9	28.9
1088 China	2004	41.6	24.5	100	100	1295	100	99.8	99	90.9	79.4	65	51.1	41	29.5
1089 China	2005	44.1	25	100	100	1302.077	100	99.9	98.6	92	81.5	67.5	53.8	45.3	35.8
1090 China	2006	48.2	28	100	100	1309.099	100	99.9	99.3	94.1	88	76.7	62.2	50.4	40.2
1091 China	2007	48.9	28.3	100	100	1316.122	100	99.9	99.2	94.4	88.5	78.5	65.8	52.8	42.9
1092 China	2008	48.1	29	100	100	1323.144	100	99.9	99.5	94.9	88	78.5	66.5	55	46.3
1093 China	2009	45.9	26.5	100	100	1330.166	100	99.9	99.1	93.1	83.8	70.6	59.3	50.4	41.6
1094 China	2010	45.5	26.9	100	100	1337.189	100	99.9	98.9	91.2	80.6	67.1	54.6	47.5	40.6
1095 China	2011	50.4	29.4	100	100	1344.15	100	99.9	99.3	95.3	89	80.4	66.3	55.4	46.1
1096 China	2012	46.7	28.4	100	100	1351.11	100	99.2	97.5	84.2	73.1	60.2	49.4	38.4	30.1
1097 China	2013	49.4	27.7	100	100	1358.071	100	99.8	99.1	93.1	84.5	72.3	61.3	53.2	44.6
1098 China	2014	52.2	29.6	100	100	1365.032	100	99.5	96.2	89.9	80.6	70.6	60.5	51	42.2
1099 China	2015	50.2	31.5	100	100	1371.993	100	99.7	96.8	88.1	76	64.1	56.5	48.1	38
1100 China	2016	45.6	29.7	100	100	1377.299	100	99.6	93	82	68.6	57.2	46.5	36.1	27
1101 China	2017	43.4	26.1	100	100	1382.604	100	99.9	99.2	92.4	81.3	67.5	53.8	42.7	31.4
1102 China	2018	39.1	24.8	100	100	1387.91	100	99.9	98.6	86.6	72.5	55.9	41.8	32.3	22.7
1103 China	2019	38.3	24.2	100	100	1393.215	100	99.7	98.8	85.8	68.7	53.8	41.2	29.7	20.2
1104 China	2020	34.4	23.3	100	100	1398.52	100	99.7	98.5	75.2	56.9	43	30.2	21.3	12.6
1105 China	2021	32.3	22.6	100	100	1398.52	100	99.9	98.9	74.4	52.8	37.3	23.9	11.5	2.3
1106 China	2022	32.2	22.6	100	100	1398.52	100	99.8	98.4	70.5	53.5	36.7	23	10.8	5.1
1107 China	2023	33.3	23.1	100	100	1398.52	100	99.8	98.7	75.9	59.2	43.4	25.2	12	4.6
1108 China	2024	32.6	23.1	100	100	1398.52	100	99.9	99	72.5	57.6	40.3	24.5	9.6	3.5
1109 CA 'te d'Ivoire	1998	19.7	21.5	100	100	16.473	100	100	97.2	8.5	0.1	0	0	0	0

pm.org/v6-gl-03

50%

Search

Data Access Tools & Examples Archive Publications Support Team

monthly datasets are provided in NetCDF [nc] format. Gridded files use projection.

These estimates are primarily intended to aid in large-scale studies. Annual -resolution averages correspond to a simple mean of within-grid values. Datasets are provided to allow users to aggregate data as best meets their needs. High-resolution (0.01° × 0.01°) datasets are gridded at the finest resolution. If the information sources that were incorporated, but are unlikely to fully capture gradients at the gridded resolution due to the influence of information at coarser resolution.

monthly mean PM_{2.5} [µg/m3] at 0.01° × 0.01°:
[satpm.org/v6gl-03-FineResolution](#)

monthly mean PM_{2.5} [µg/m3] at 0.1° × 0.1°:
[satpm.org/v6gl-03-CoarseResolution](#)

PM_{2.5} data is alternatively available via the Registry of Open Data on AWS:
[registry.opendata.aws/surface-pm2-5-v6gl/](#)

Configured to comply with WashU's Cloud Security policy.

055:
aws s3 sync --no-sign-request s3://satpmdata/V6GL03/

3. Download via AWS CLI
Use 'aws s3 sync' to download a specific folder or file:

```
aws s3 sync s3://satpmdata/V6GL03/<path/to/folder> <local-destination>
```

Replace '<path/to/folder>' with the path to the desired folder or file, and '<local-destination>' with the path to the local destination.

Processed Datasets:
These summary files are processed from the Scientific Datasets above for ease of accessibility. Population-weighted estimates and total population describe only those people covered by the SatPM V6.GL.03 dataset and are provided by GPWv4. Country borders are defined following GAD3.6.


- [Annual Global country-level mean PM_{2.5}](#)
- [Annual Canada provincial-level mean PM_{2.5}](#)
- [Annual China regional-level mean PM_{2.5}](#)
- [Annual India regional-level mean PM_{2.5}](#)
- [Annual United States state-level mean PM_{2.5}](#)

SatPM_{2.5} V6.GL.03 are licensed under [CC-BY 4.0](#)

datos/instrucciones de acceso
mediante Carpetas
y a través del Registro de Datos
Abiertos AWS

Los conjuntos de datos
procesados proporcionan
resúmenes simplificados





monthly datasets are provided in NetCDF [nc] format. Gridded files use projection.

These estimates are primarily intended to aid in large-scale studies. Annual -resolution averages correspond to a simple mean of within-grid values. Assets are provided to allow users to aggregate data as best meets their needs. High-resolution (0.01° × 0.01°) datasets are gridded at the finest resolution of the information sources that were incorporated, but are unlikely to fully capture gradients at the gridded resolution due to the influence of information at coarser resolution.

monthly mean PM_{2.5} [µg/m³] at 0.01° × 0.01°:
data.nasa.gov/satpm/v6-gl-03

monthly mean PM_{2.5} [µg/m³] at 0.1° × 0.1°:
data.nasa.gov/satpm/v6-gl-03

PM_{2.5} data is alternatively available via the Registry of Open Data on AWS:
registry.opendata.aws/surface-pm2-5-v6gl/

configured to comply with WashU's Cloud Security policy.

Users:
 Users can download files directly through the secure web portal:
data.nasa.gov/satpm/v6-gl-03
 or via AWS CLI (listing only): No credentials required for listing:
 --no-sign-request aws s3://satpmdata/V6GL03/

Datos/Instrucciones de Acceso
 mediante Carpetas
 y a través del Registro de Datos
 Abiertos AWS

Los conjuntos de datos
 procesados proporcionan
 resúmenes simplificados

3. Download via AWS CLI
 Use 'aws s3 sync' to download a specific folder or file:

```
aws s3 sync s3://satpmdata/V6GL03/<path/to/folder> <local-destination>
```

Replace '<path/to/folder>' with the path to the desired folder or file, and '<local-destination>' with the path to the local destination.

Processed Datasets:
 These summary files are processed from the Scientific Datasets above for ease of accessibility. Population-weighted estimates and total population describe only those people covered by the SatPM V6.GL.03 dataset and are provided by GPWv4. Country borders are defined following GADM.

- Annual Global country-level mean PM_{2.5}
- Annual Canada provincial-level mean PM_{2.5}
- Annual China regional-level mean PM_{2.5}
- Annual India regional-level mean PM_{2.5}
- Annual United States state-level mean PM_{2.5}

SatPM_{2.5} V6.GL.03 are licensed under [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)



Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5

Las versiones anteriores se
archivan para su acceso
posterior

Home | satpm.org

← → ↻ 🔒 www.satpm.org 50% ☆ 🔍 Search

SatPM Home Data Access Tools & Examples Archive Publications Support Team

Satellite-Derived

Data on the distribution of fine particulate matter (PM_{2.5}) in air quality assessment, research, and management. SatPM satellite-derived PM_{2.5} datasets offer:

- Global coverage of fine particulate matter concentration
- Multi-year records for trend analysis (1998-present)
- Multiple product versions tailored to regional and temporal needs

SatPM V6.GL.02.04
SatPM V6.GL.01
SatPM V5.NA.05
SatPM V5.GL.05.02
SatPM V5.GL.04
SatPM V5.GL.03
SatPM V5.NA.04.02
SatPM V5.GL.02
SatPM V5.GL.01
SatPM V4.GL.03
SatPM V4.NA.03
SatPM V4.EU.03
SatPM V4.CH.03
SatPM V4.NA.02.MAPLE
SatPM V4.CH.02
SatPM V4.EU.02
SatPM V4.GL.02
SatPM V4.NA.01
SatPM V3.01
SatPM V1.01

V6.GL.03 (µg/m³)
Obs (µg/m³)
R²=0.80

2024 PM_{2.5} (µg/m³)

SatPM global and regional PM_{2.5} concentrations combine the observational constraint of satellite retrievals, the coverage and insight of process-based simulations and data-driven algorithms, and the accuracy of ground-based measurements.

Aerosol observed throughout the atmospheric column from multiple satellite-based instruments ([MODIS/Terra](#), [MODIS/Aqua](#), [MISR/Terra](#), [SeaWiFS/SeaStar](#), [VIIRS/SNPP](#), and [VIIRS/NOAA20](#)) and their respective retrievals ([Dark Target](#), [Deep Blue](#), [MAIA2](#)) are related to near surface PM_{2.5} concentrations using the [GEOS-Chem](#) chemical transport model, where GEOS-Chem provides the spatially and temporally varying relationship between aerosol optical depth and PM_{2.5}. Targeted observations (e.g., [SPARTAN](#)) are used for process-level evaluation of algorithms. A collection of ground-based observations from around the world (e.g., [WHO Ambient Air quality database](#), [OpenAQ](#), national regulatory networks, SPARTAN) are then used to refine these initial estimates using advanced statistical fusion and deep-learning techniques.

Satellite
PM_{2.5}
Simulation Monitors

SatPM
Satellite-Derived Particulate Matter

Join our mailing list for updates on data products and events

Email *


www.satpm.org/archive



Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5

Las versiones anteriores se
archivan para su acceso
posterior

**Equipo de apoyo dedicado
disponible para ayudar**



Sitio web dedicado
(www.satpm.org) Proporciona
acceso a las últimas versiones de
SatPM2.5


Las versiones anteriores se
archivan para su acceso
posterior

Equipo de apoyo dedicado
disponible para ayudar

**¡Regístrese para recibir
actualizaciones sobre
productos de datos!**

The screenshot displays the SatPM website interface. At the top, the browser address bar shows 'Home | satpm.org'. The website header includes the SatPM logo and navigation links: Home, Data Access, Tools & Examples, Archive, Publications, and Support Team. The main content area features two global maps of PM_{2.5} concentrations, with a color scale ranging from 3 to 200 µg/m³. Below the maps, a scatter plot shows the relationship between V6 GL03 (µg/m³) and Obs (µg/m³), with an R² value of 0.80. A text block explains that SatPM global and regional PM_{2.5} concentrations combine observational constraints, satellite retrievals, process-based simulations, and ground-based measurements. To the right, a diagram illustrates the integration of Satellite, Simulation, and Monitors data for PM_{2.5}. Below this, a detailed paragraph describes the data sources and processing methods, including satellite-based instruments (MODIS/Terra, MODIS/Aqua, MISR/Terra, SeaWiFS/SeaStar, VIIRS/SNPP, and VIIRS/NOAA20), their retrievals (Dark Target, Deep Blue, MAIAC), and the use of the GEOS-Chem chemical transport model. A collection of ground-based observations (e.g., WHO Ambient Air quality database, OpenAQ, national regulatory networks, SPARTAN) are used to refine the initial estimates. At the bottom, a mailing list sign-up form is highlighted with a yellow circle, containing fields for Email, Full name, Organization, and a Submit button. The footer includes the text '© 2025 by Washington University in St. Louis'.





Aprendizaje automático directo para $PM_{2.5}$

Enfoques directos de aprendizaje automático para la estimación de $\text{PM}_{2.5}$ en la superficie

- Un modelo de Aprendizaje Automático (ML) aprende el mapeo a partir de las entradas de satélite/reanálisis de $\text{PM}_{2.5}$ en la superficie sin un modelo de transporte químico en el bucle.

Geofísico

Sección 1

El modelo de transporte químico (CTM) proporciona la física de conversión de AOD $\rightarrow$ $\text{PM}_{2.5}$. El AOD satelital limita el resultado.

ej., MERRA-2, GEOS-Chem-based products

Híbrido

Secciones 1–2

Parte de una estimación geofísica; luego se calibra con monitores terrestres usando GWR, estadística o métodos de aprendizaje automático como una CNN.

ej., WashU SatPM2.5

Direct ML

Esta Sección

El modelo de aprendizaje automático aprende el mapeo de extremo a extremo solo a partir de observaciones — sin andamiaje de un CTM.

ej., GHAP, MERRA2_CNN_HAQAST_PM25


Por qué creció el ML directo: Los archivos satelitales + de reanálisis, las redes de monitores terrestres (por ejemplo, OpenAQ) y la computación GPU hicieron que los enfoques basados en datos fueran manejables y, a menudo, más flexibles en regiones donde los inventarios de emisiones de CTM son débiles.



Aplicaciones PM_{2.5} basadas en ML a través de diferentes horizontes temporales



Flujo de trabajo típico de estimación PM_{2.5} basada en aprendizaje automático




1

Insumo primario

AOD de satélite, aerosoles de reanálisis

MODIS, VIIRS, MISR, SeaWiFS,
GOES-R/Geo, MERRA-2, CAMS



2

Campos auxiliares

Mayormente de Reanálisis(ERA-5, MERRA-2)

Humedad, altura de la capa límite,
temperatura, vientos, presión
superficial, cobertura terrestre



3

Verdad de fondo

Variable objetivo—PM_{2.5} In-Situ

EPA AirNow, OpenAQ, Redes
Regionales

MODELO ML


Random Forest
XGBoost
CNN, DNN, LSTM,
GNN, Transformer

SALIDA


PM_{2.5} Superficial

($\mu\text{g}/\text{m}^3$)

En cuadrícula de
satélite/reanálisis








Park et al., (2025)



Sayeed et al., (2022)



De Señal de Satélite a PM_{2.5} en la Superficie – El Método ML



Fuente: Park et al., (2025)

Fuente: US EPA



PASO 01

Acquirir datos

Obtener AOD de las recuperaciones satelitales y PM_{2.5} de las estaciones de monitorización en tierra.

Satellite AOD

Ground PM_{2.5}



PASO 02

Colocalizar

Coincide en tiempo (más cerca del paso elevado) y espacio (píxel más cercano o media local).

Temporal match

Spatial match



PASO 03

Construir el Modelo

Aplicar modelos de regresión o aprendizaje automático para predecir PM_{2.5} a partir de AOD satelital.

AOD ↔ PM_{2.5}

Statistical & AI/ML



PASO 04

Estimar PM_{2.5}

Derivar la superficie PM_{2.5} usando AOD en columna.

Regression

Machine Learning



PASO 05 (OPCIONAL)

Convertir en AQI

Traducir las concentraciones de PM_{2.5} en el Índice de Calidad del Aire (AQI).

Concentration

AQI category



Ejemplos de conjuntos de datos PM2.5 basados en aprendizaje automático en modos temporales

	◀ Histórico/Retrospectivo	▶ En tiempo casi real	▶▶ Previsión
Ejemplos	Di et al. (2019) — CONUS, ensemble (NN + RF + GB) Park et al. (2020) — East Asia, RF + GOCI AOD Wei et al. (2023) — Global, big-data ML (GHAP)	Pendergrass et al. (2022) — East Asia, RF + GOCI Sayeed et al. (2025) — CONUS, DNN + GOES-R Zhang & Kondragunta (2024) — CONUS, DNN + geostationary	Sayeed et al. (2021) — CONUS, CNN + CMAQ Lee et al. (2022) — East Asia, ML + DA + GOCI Seo & Gupta (2026) — Global, TCN + MoE + GEOS-FP
Insumos	MODIS/MAIAC AOD, GOCI, PM _{2.5} modelado, reanálisis metido, cobertura del terreno, monitores de suelo	AOD geoestacionario (GOES-R / Goci), Radiance, HRRR / NRT met, AirNow / AirKorea	Pronóstico meteorológico (CMAQ, GEOS-FP, WRF), observaciones terrestres - sin AOD actual
Métodos	Ensemble (NN + RF + GB), Random Forest, big-data ML with gap-filling	RF/LGBM/DNN corrección de sesgos de productos operativos; AOD con huecos	CNN/TCN corrección de sesgos de las previsiones de la MCC; asimilación de datos + ML; Mezcla de expertos
Patrón común de ML	Principalmente estimación directa : los archivos de datos ricos soportan mapeo completo de ML	A menudo corrección de sesgo de un producto operativo (GOES-GWR, CAMS)	Predominantemente corrección de sesgo de las previsiones de CTM
Aspectos destacados	Global daily 1 km gapless (GHAP); CONUS 1 km ensemble widely used in health studies (Di et al. 2019)	RMSE ↓ 8.72 → 6.55 µg/m³ (Sayeed et al. 2025); DNN beats RF/LGBM by up to ~45% IOA	Reliable 2-day forecast; DA + ML improves PM _{2.5} analysis; R²=0.88, captures wildfire peaks



Fortalezas y limitaciones del $PM_{2.5}$ basado en ML


✓ Fortalezas

- Captura relaciones no lineales AOD ↔ $PM_{2.5}$
- Flexible en regiones con inventarios escasos de emisiones de CTM
- Puede incorporar diversos predictores (meta, cobertura del terreno, tiempo)
- Reduce los sesgos sistemáticos de estimaciones basadas en la física
- Inferencia rápida una vez entrenada

✗ Limitaciones

- Depends heavily on density and quality de monitores en tierra; ¡El currículum espacial es importante!
- Riesgo de bajo rendimiento en eventos extremos (incendios forestales) si se está infrarrepresentado en el entrenamiento
- Menos interpretabilidad mecanicista que los métodos basados en CTM
- Las brechas AOD de los satélites (nubes, nieve) se propagan a $PM_{2.5}$
- La generalización entre regiones y periodos no está garantizada





Ejemplo: MERRA-2 corregido por sesgo

Visión comparativa de los productos globales de PM2.5

Conjunto de datos	Cobertura temporal	Resolución	Fuente/Método
DeepCAMS	2003–2020	0.25°, cada hora	CAMS + Ground + Deep Learning
Global High Air Pollutants (GHAP)	2017–2022	1 km, diaria	Satellite + Ground + Deep Learning
Berkeley Earth Real-time AQ	Real-time	0.10°, lagunas de datos	Mediciones en tierra + Interpolación
WashU SatPM	1998–2023	1 km, mensual/anual	Satellite + Models + Ground
MERRA2_CNN_HAQAST_PM25	2000–2024	0.5° × 0.625°, cada hora	MERRA-2 + CNN Ensemble + OpenAQ

MERRA2_CNN_HAQAST_PM25 Niche:

A largo plazo (25 años), globalmente completo, por horas y corregido por sesgo, cubriendo el vacío dejado por productos diarios/mensuales y productos horarios de registro corto.



Visión General del Producto MERRA2_CNN_HAQAST_PM25

Cobertura temporal

2000–2024 (actualizado periódicamente)

Resolución temporal

Horario (00:30–23:30 UTC)

Resolución espacial

0,5° de latitud × 0,625° de longitud

Cobertura espacial

Global (90°S–90°N, 180°W–180°E)

Formato de archivo

NetCDF, ~14 MB por archivo diario


Variables

MERRA2_CNN_Surface_PM25 ($\mu\text{g}/\text{m}^3$), QFLAG (1–4)

DOI: Gupta and Sayeed (2026)
10.5067/OCKK5HCFW5N3

MERRA-2 Bias corrected surface total PM_{2.5} mass concentration

January 1, 2023 00:30 UTC




**PM_{2.5} en la superficie total corregido por sesgo —
1^{ro} de enero de 2023, 00:30 UTC.**



Control de Calidad de MERRA2_CNN_HAQAST_PM25

- Quality Flag (QFLAG) proporciona un indicador cualitativo de la calidad de los datos
- QFLAG determinado en función de la proximidad a los monitores de superficie, tipo cobertura del suelo y latitud
- Valores de QFLAG del 1 al 4
 - QFLAG = 1: Baja calidad de datos
 - QFLAG = 2: Calidad Media de Datos
 - QFLAG = 3: Alta Calidad de Datos
 - QFLAG = 4: Mejor calidad de datos
- **Use QFLAG ≥ 3 para análisis cuantitativo.**



**PM_{2.5} en la superficie total corregido por sesgo —
8 de junio 2023, 00:30 UTC.**

El mapa insertado muestra la bandera de calidad QFLAG en cada punto de la cuadrícula (1 = bajo, 4 = mejor).



Motivación para la Corrección de Sesgos del PM_{2.5} de MERRA-2


- El PM_{2.5} de MERRA-2 se calcula empíricamente:

$$\text{PM}_{2.5} = \text{POLVO}_{2.5} + \text{SS}_{2.5} + \text{BC} + \text{OC} + 1.375 \times \text{SO}_4$$

- **Especies faltantes:** Sin nitratos, sin amonio — ambos pueden contribuir sustancialmente en muchas regiones
- **Promediado de cuadrícula:** ~50 × 65 km Las celdas suavizan sobre fuentes y gradientes locales
- **Emisiones y Hipótesis Meteorológicas:** El sesgo varía según la región y la temporada
- **Tamaño y composición del aerosol:** Semivolátiles y crecimiento higroscópico no capturados



Sesgo medio de MERRA-2 PM_{2.5} en bruto frente a monitores terrestres en 2020



- Los patrones de sesgo varían según la región y el régimen de aerosoles
- El enfoque de aprendizaje automático puede corregir estos sesgos

Resultado: sesgo regionalmente variable

Sobreestimación: California, este de China, Oriente Medio
($> +20 \mu\text{g}/\text{m}^3$)

Subestimación: Llanura Indo-Gangética, sur de Sudamérica
($< -15 \mu\text{g}/\text{m}^3$)



Insumos: Aerosoles y Meteorología para MERRA-2

- Seleccionados en función de su conexión geofísica con la formación, transporte y eliminación de $PM_{2.5}$ en la superficie.

Diagnóstico de aerosoles (M2T1NXAER)

BCSMASS	Masa superficial de carbono negro
OCSMASS	Masa superficial de carbono orgánico
DUSMASS25	Masa superficial de polvo (fracción $PM_{2.5}$)
SO2SMASS	Masa superficial de SO_2
SO4SMASS	Masa superficial de sulfato
TOTEXTTAU	AOT de extinción total de aerosoles (550 nm)

Meteorología (M2T1NXSLV)

PS	Presión superficial
QV10m, Q500	Humedad específica (10 m, 500 hPa)
T10m, T500, T850	Temperatura (10 m, 500, 850 hPa)
U10, V10	Componentes eólicos a 10 m

Todos los insumos están en resolución nativa de MERRA-2 ($0,5^\circ \times 0,625^\circ$, cada hora) — lo que asegura que el producto de salida herede la misma cuadrícula y cronología.



La Verdad en el Suelo: Observaciones de calidad de referencia de OpenAQ

- Observaciones $PM_{2.5}$ de calidad de referencia obtenidas de OpenAQ
- Cómo se usaron los datos de OpenAQ:
 - Cada estación está colocada espacialmente con su punto de cuadrícula MERRA-2 más cercano
 - Los valores de $PM_{2.5}$ de cada hora se emparejan temporalmente con los insumos de MERRA-2
 - Se aplica control de calidad para eliminar casos atípicos y registros inválidos
 - División: entrenamiento de 2018 a 2019, validación independiente en 2020

5,187

Estaciones de monitoreo en todo el mundo

30.4M


Observaciones de Cada Hora Colocalizadas Válidas

2018–2020

Periodo de recolección de datos



Metodología: De insumos de MERRA-2 hasta PM_{2.5} corregido por sesgos





[Gupta y Sayeed, 2026](#)

1. Insumos de MERRA-2 colocalizadas espacial y temporalmente con PM_{2.5} superficial de OpenAQ
2. Cinco estrategias de procesamiento de datos conscientes de aerosoles (M1-M5) entrenan cada una a una CNN independiente
3. La CNN de conjunto "Ensemble" - (M6) combina las salidas M1-M5 → valor PM_{2.5} corregido por sesgo único por cuadrícula y hora




Cinco estrategias conscientes de los aerosoles → un conjunto

- Cada estrategia forma a una CNN independiente; sus predicciones se combinan mediante un modelo final de conjunto (M6)



Validation: M6 reduce el sesgo dependiente de la concentración en MERRA-2.



Configuración

PM_{2.5} observado se agrupó en 10 cuantiles (percentil 1 a 99).

M6 (Azul)

Rastrea la línea 1:1 a lo largo de todo el rango de concentración y se mantiene dentro de la banda de $\pm 2\sigma$.


MERRA-2 (Rojo)

Sobreestima sistemáticamente en un PM_{2.5} bajo; subestima en un alto PM_{2.5}. Ambos efectos son visibles tanto en el entrenamiento como en la validación.

[Gupta y Sayeed, 2026](#)



Validación: M6 reduce sustancialmente el sesgo entre regiones en MERRA-2.



Hallazgos clave:

MERRA-2 (Superior)

Amplio Rango de Error: $> +20 \mu\text{g}/\text{m}^3$ en California, este de China, Oriente Medio; $< -15 \mu\text{g}/\text{m}^3$ en la Llanura Indo-Gangética, sur de Sudamérica.

M6 (Inferior)

Reducción sustancial del sesgo, patrones de error más localizados y mejor calibración entre diversos regímenes de aerosoles.


Advertencia honesta

Sigue habiendo cierta sobrepredicción en el M6 en el este y sudeste asiático en concentraciones elevadas, aunque la IOA sigue superando a MERRA-2 allí.



Rendimiento regional: M6 supera a MERRA-2 en todas partes

Índice de Concordancia Mediano (IOA) por región — más alto es mejor, máximo = 1.



Qué medidas de la IOA

El Índice de Concordancia (Index of Agreement o IOA) califica qué tan bien las predicciones reproducen tanto la magnitud como el patrón. Más cerca de 1 es mejor.

Casi 2× mejor

En el sudeste asiático (0.76 vs. 0.39) y el sur de Asia (0.82 vs. 0.47).

Conclusión

M6 reproduce mejor la variabilidad temporal y espacial de PM_{2.5}.



Resumen de MERRA2_CNN_HAQAST_PM25 MERRA-2 Corregido por Sesgo PM2.5


✓ **A largo plazo, global, cada hora**
Cobertura 2000–2024 a resolución nativa MERRA-2 de 0,5°×0,625°.

✓ **Corregido por sesgo vía Ensemble CNN**
Estratificación consciente de aerosoles (M1–M5) combinada en un conjunto (M6).

✓ **Mejora el PM_{2.5} respecto a MERRA-2**
Mayor IOA, sesgo espacial reducido, robusto para años y regiones no vistos.

✓ **Consciente de la calidad**
QFLAG permite el filtrado;
use ≥ 3 para trabajo cuantitativo.






Acceso a datos de MERRA-2 corregidos por sesgo

Opciones de acceso a datos


Recurso	Descripción
<u>Página de Inicio de Datos</u>	Fuente principal de información sobre el producto, incluyendo opciones de acceso y enlaces a otros recursos
<u>Documento Readme</u>	Descripción detallada del conjunto de datos y el formato de los archivos de datos
<u>Archivo en Línea</u>	Descarga de archivos individuales
<u>Búsqueda Earthdata</u>	Búsqueda y descarga de conjuntos de archivos para un intervalo de tiempo específico
<u>AWS</u>	Acceso directo a los datos en la nube de Amazon S3
<u>OPeNDAP</u>	Acceso remoto a archivos usando lenguajes y herramientas de programación comunes(ej., Python, Matlab, R, Panoply)
<u>Giovanni</u>	Herramienta en línea para subagrupar, promediar y graficar datos (por ejemplo, mapa, series temporales)



A decorative graphic consisting of a grid of colored squares in shades of blue, green, and yellow, arranged in a pattern that resembles a stylized letter 'L' or a corner.



Visualización de $PM_{2.5}$ de MERRA-2 corregido por sesgo con Giovanni de la NASA



Parte 2: **Resumen**

Resumen

SatPM_{2.5} de Washington University en St. Louis

- Metodología:
 - Híbrida-Geofísica
- Fortalezas:
 - Resolución espacial fina ($0.01^{\circ} \times 0.01^{\circ}$)
 - Historial largo (1998-2024)
 - Rendimiento constante incluso lejos de los monitores terrestres
- Limitaciones:
 - Resolución temporal mensual
- Acceso a datos:
 - Libre y gratuito
 - <http://satpm.org>


MERRA-2 PM_{2.5} corregido por sesgo por la NASA

- Metodología:
 - Ensemble CNN
- Fortalezas:
 - Resolución temporal horaria
 - Historial largo (2000-2025)
 - Representa mejor la variabilidad espacial y temporal de PM_{2.5} en comparación con MERRA-2
- Limitaciones:
 - Resolución espacial gruesa ($0.5^{\circ} \times 0.625^{\circ}$)
- Acceso a datos:
 - Libre y gratuito
 - [NASA Earthdata \(GES DISC\)](#)
 - e.g., análisis en línea con Giovanni



Mirando hacia la Parte 3

En la Parte 3, presentaremos un estudio de caso comparando SatPM_{2.5} y MERRA-2 PM_{2.5} corregido por sesgo con datos de monitores terrestres, demostrando cómo acceder y evaluar estos datos en aplicaciones prácticas.



Preparación para la Parte 3

Para prepararse para la parte 3, por favor asegúrese de:

- Tener acceso a [Google Colab](#), usando una cuenta gratuita de [Google o Gmail](#).
- Tener una cuenta gratis de [NASA Earthdata](#) y saber su nombre de usuario y contraseña.
- Tener una cuenta gratis de [OpenAQ](#) y saber su clave para la interfaz [OpenAQ API](#).



Tarea y Certificados

- **Tarea:**

- Se asignará una tarea
- Abre el 22 de julio de 2026
- Acceder desde la [página web de la capacitación](#)
- Debe enviar sus respuestas vía Formularios de Google
- **Fecha límite: 5 de agosto de 2026**

- **Certificado de Finalización de Curso:**

- Asista a los tres webinars en vivo (la asistencia se registra automáticamente)
- Complete la tarea antes de la fecha límite
- Recibirá un certificado por correo electrónico aproximadamente dos meses después de completar el curso.

Datos de contacto

Formadores:

- Carl Malings
 - carl.a.malings@nasa.gov
- Pawan Gupta
 - pawan.gupta@nasa.gov
- Aaron van Donkelaar
 - aaron.vandonkelaar@wustl.edu
- Junhyeon Seo
 - junhyeon.seo@nasa.gov

- [Página Web de ARSET](#)
- [ARSET en YouTube](#)

Para hacer preguntas, comentarios, o compartir cómo ha aplicado nuestras capacitaciones a su trabajo o estudios, envíe un correo a nasa.arset@gmail.com.

Inscríbase para recibir nuestro boletín trimestral para estar al tanto de nuestras nuevas capacitaciones:

1. Envíe un correo sin asunto a arset-join@lists.nasa.gov.
2. Siga las instrucciones que se le enviarán en la respuesta.



Referencias

- Martin, R. V., M. Brauer, A. van Donkelaar, G. Shaddick, U. Narain, S. Dey (2019). "No one knows which city has the highest concentration of fine particulate matter", *Atmos. Environ.*, [doi:10.1016/j.aeaoa.2019.100040](https://doi.org/10.1016/j.aeaoa.2019.100040).
- van Donkelaar, A., R. V. Martin, R. J. D. Spurr y R. T. Burnett (2015). "High-resolution satellite-derived PM_{2.5} from optimal estimation and geographically weighted regression over North America", *Environ. Sci. and Tech.*, [doi:10.1021/acs.est.5b02076](https://doi.org/10.1021/acs.est.5b02076).
- Shen, S., Li, C. van Donkelaar, A. Jacobs, N. Wang, C. Martin, R. V. (2024). "Enhancing Global Estimation of Fine Particulate Matter Concentrations by Including Geophysical a Priori Information in Deep Learning", *ACS ES&T Air*, [doi:10.1021/acsestair.3c00054](https://doi.org/10.1021/acsestair.3c00054).
- Shen, S., van Donkelaar, A., Jacobs, N., Li, C., y Martin, R. V. (2026). "Enhancing Estimation of Fine Particulate Matter Chemical Composition across North America by Including Geophysical A Priori Information in Deep Learning with Uncertainty Quantification", *ACS ES&T Air*, [doi:10.1021/acsestair.5c00025](https://doi.org/10.1021/acsestair.5c00025).
- Hammer, M. S., A. van Donkelaar, C. Li, A. Lyapustin, A. M. Sayer, N. C. Hsu, R. C., Levy, M. Garay, O. Kalashnikova, R. A. Kahn, M. Brauer, J. S. Apte, D. K. Henze, L. Zhang, Q. Zhang, B. Ford, J. R. Pierce, R. V. Martin (2020). "Global Estimates and Long-Term Trends of Fine Particulate Matter Concentrations (1998-2018)", *Environ. Sci. Technol.*, [doi:10.1021/acs.est.oco1764](https://doi.org/10.1021/acs.est.oco1764).
- van Donkelaar, A., Hammer, M. S., Bindle, L., Brauer, M., Brook, J. R., Garay, M. J., Hsu, N. C., Kalashnikova, O. V., Kahn, R. A., Lee, C., Levy, R. C., Lyapustin, A., Sayer, A. M., y Martin, R. V. (2021). "Monthly Global Estimates of Fine Particulate Matter and Their Uncertainty", *Environ. Sci. Technol.*, [doi:10.1021/acs.est.1c05309](https://doi.org/10.1021/acs.est.1c05309).
- van Donkelaar, A., R.V. Martin, and R.J. Park (2006). "Estimating ground-level PM_{2.5} using aerosol optical depth determined from satellite remote sensing", *J. Geophys. Res.*, 111, D21201, [doi:10.1029/2005JD006996](https://doi.org/10.1029/2005JD006996).
- Hoff y Christopher (2009). "Remote Sensing of Particulate Pollution from Space: Have we reached the promised land?" *Journal of the Air & Waste Management Association*; 59, 642-675, [doi:10.3155/1047-3289.59.6.645](https://doi.org/10.3155/1047-3289.59.6.645).



Referencias

- Gupta, P., y A. Sayeed (2026). "MERRA2_CNN_HAQUEST_PM25: Hourly Bias-Corrected PM2.5 Datasets for Global Air Quality Assessment." *Geoscience Data Journal* 13, no. 2: e70070. [doi:10.1002/gdj3.70070](https://doi.org/10.1002/gdj3.70070).
- Di, Q., et al. (2019). An ensemble-based model of PM_{2.5} concentration across the contiguous United States with high spatiotemporal resolution. *Environment International*, 130, 104909. [doi:10.1016/j.envint.2019.104909](https://doi.org/10.1016/j.envint.2019.104909)
- Wei, J., et al. (2023). First close insight into global daily gapless 1 km PM_{2.5} pollution, variability, and health impact. *Nature Communications*, 14, 8195. [GHAP] [doi:10.1038/s41467-023-43862-3](https://doi.org/10.1038/s41467-023-43862-3)
- Park, S., et al. (2020). Estimation of spatially continuous daytime particulate matter concentrations under all sky conditions through the synergistic use of satellite-based AOD and numerical models. *Science of the Total Environment*, 713, 136516. [doi:10.1016/j.scitotenv.2020.136516](https://doi.org/10.1016/j.scitotenv.2020.136516)
- Pendergrass, D. C., et al. (2022). Continuous mapping of fine particulate matter (PM_{2.5}) air quality in East Asia at daily 6 × 6 km² resolution by application of a random forest algorithm to 2011–2019 GOCI geostationary satellite data. *Atmospheric Measurement Techniques*, 15, 1075–1091. [doi:10.5194/amt-15-1075-2022](https://doi.org/10.5194/amt-15-1075-2022)
- Sayeed, A., et al. (2025). GOES-R PM_{2.5} Evaluation and Bias Correction: A Deep Learning Approach. *Earth and Space Science*, 12, e2024EA004012. [doi:10.1029/2024EA004012](https://doi.org/10.1029/2024EA004012)
- Zhang, H. & Kondragunta, S. (2024). Hour by Hour PM_{2.5} Mapping Using Geostationary Satellites. *ACS ES&T Air*. [doi:10.1021/acsestair.4c00365](https://doi.org/10.1021/acsestair.4c00365)
- Sayeed, A., et al. (2021). Bias correcting and extending the PM forecast by CMAQ up to 7 days using deep convolutional neural networks. *Atmospheric Environment*, 253, 118376. [doi:10.1016/j.atmosenv.2021.118376](https://doi.org/10.1016/j.atmosenv.2021.118376)



Referencias

- Lee, S., et al. (2022). Air Quality Forecasts Improved by Combining Data Assimilation and Machine Learning With Satellite AOD . *Geophysical Research Letters*, 49, e2021GL096066. [doi:10.1029/2021GL096066](https://doi.org/10.1029/2021GL096066)
- Seo, J. y Gupta, P. (2026). Adaptive expert-guided deep imbalanced regression for global PM_{2.5} forecasting with temporal convolutional networks and GEOS-FP inputs. *npj Climate and Atmospheric Science*. [doi:10.1038/s41612-026-01437-1](https://doi.org/10.1038/s41612-026-01437-1)





¡Gracias!

