

Directrices de la OMM para la elaboración de atlas nacionales de recursos energéticos renovables: energía eólica, solar e hidroeléctrica

Orientaciones para los Servicios Meteorológicos e Hidrológicos Nacionales sobre la elaboración de atlas de alta resolución de recursos eólicos, solares e hidroeléctricos basados en datos de simulación, observacionales y de proyecciones climáticas



ORGANIZACIÓN
METEOROLÓGICA
MUNDIAL



Directrices de la OMM para la elaboración de atlas nacionales de recursos energéticos renovables: energía eólica, solar e hidroeléctrica

Orientaciones para los Servicios Meteorológicos e Hidrológicos Nacionales sobre la elaboración de atlas de alta resolución de recursos eólicos, solares e hidroeléctricos basados en datos de simulación, observacionales y de proyecciones climáticas



ORGANIZACIÓN
METEOROLÓGICA
MUNDIAL

© Organización Meteorológica Mundial, 2026

La OMM se reserva el derecho de publicación en forma impresa, electrónica o de otro tipo y en cualquier idioma. Pueden reproducirse pasajes breves de las publicaciones de la OMM sin autorización siempre que se indique claramente la fuente completa. La correspondencia editorial, así como todas las solicitudes para publicar, reproducir o traducir la presente publicación parcial o totalmente deberán dirigirse al:

Presidente de la Junta de Publicaciones
Organización Meteorológica Mundial (OMM)
7 bis, avenue de la Paix
Case postale N° 2300
CH-1211 Genève 2, Suiza

Correo electrónico: publications@wmo.int

NOTA

Las denominaciones empleadas en la presente publicación y la forma en que aparecen presentados los datos que contiene no implican, de parte de la Secretaría de la OMM ni de la Secretaría de las Naciones Unidas, juicio alguno sobre la condición jurídica de países, áreas o territorios, o de sus autoridades, ni respecto de la delimitación de sus límites. No se garantiza que la representación y el uso de los límites, los nombres geográficos y los datos conexos que figuran en los mapas y que se incluyen en las listas, los cuadros, los documentos o las bases de datos de la presente publicación estén totalmente libres de errores ni tampoco implican la aprobación o aceptación oficial de la OMM ni de las Naciones Unidas.

La mención de determinados productos o sociedades mercantiles no implica que la OMM los favorezca o recomiende con preferencia a otros análogos que no se mencionan ni se anuncian.

Autores

Sara Dal Gesso (AMIGO), Marco Venturini (AMIGO), Alessandro Moser (AMIGO), Marcello Petitta (Universidad Roma Tre), Hamid Bastani (OMM), Roberta Boscolo (OMM), Rundong Cao (OMM)

Colaboradores

José Alberto Zúñiga Mora (Instituto Costarricense de Electricidad (ICE), Costa Rica), Dylana Vargas Navarro (ICE, Costa Rica), Berny Fallas López (ICE, Costa Rica), Karina Hernández Espinoza (Instituto Meteorológico Nacional, Costa Rica), Mohammad Bagher Roshan (Organización de Energías Renovables y Eficiencia Energética, República Islámica de Irán), Ahad Vazife (Organización Meteorológica de la República Islámica del Irán, República Islámica del Irán), Lucy Mtilatila (Departamento de Cambio Climático y Servicios Meteorológicos, Malawi), Keenness Mang'anda (Departamento de Cambio Climático y Servicios Meteorológicos, Malawi), Juan Sebastián Crespo Fuentes (Dirección Meteorológica de Chile, Chile), Camila Vásquez (Ministerio de Energía, Chile), Frank Kaspar (Servicio Meteorológico de Alemania (DWD), Alemania), Rybka Harald (DWD, Alemania), Jörg Trentmann (DWD, Alemania), Kristian Horvath (Servicio Meteorológico e Hidrológico, Croacia), Vaileth Jonas (Autoridad Meteorológica de Tanzania, República Unida de Tanzania), Alfredo Roque (Instituto de Meteorología, Cuba)

Revisores

Expertos del Grupo de Estudio de la OMM sobre la Transición a las Energías Renovables (SG-RENE) de la Comisión de Aplicaciones y Servicios Meteorológicos, Climáticos, Hidrológicos, Marinos y Medioambientales Conexos de la OMM

Agradecimientos

Tobias Fuchs (DWD, Alemania), Marisol Osman (Universidad de Buenos Aires, Argentina), Anders Pedersen (Banco Mundial), Imen Gherboudj (Agencia Internacional de Energías Renovables (IRENA))

NOTA:

La presente nota figura únicamente en la versión en español de estas directrices. La traducción al español de la publicación original se realiza en el marco del proyecto Mejora de la Capacidad de Adaptación de las Comunidades Andinas a través de los Servicios Climáticos (ENANDES) en Chile, Colombia y el Perú. La financiación del proyecto procede del Fondo de Adaptación, y su ejecución corresponde a la Organización Meteorológica Mundial (OMM) a través de su Oficina Regional para las Américas.

La traducción al español se ha elaborado como parte de las actividades del proyecto ENANDES relacionadas con la energía, en concreto en el marco de la iniciativa Atlas Nacional de Energías Renovables de Alta Resolución de la OMM, cuya tercera fase se ejecuta en los países participantes de ENANDES y ENANDES+ durante 2026.

Para obtener más información sobre el Atlas Nacional de Energías Renovables de ENANDES o sobre esta publicación, sírvase consultar el juego de herramientas sobre los servicios climáticos de ENANDES (<https://crc-osa.ciifen.org/en/CST/>), póngase en contacto con la Oficina Regional para las Américas de la OMM (ram@wmo.int), o comuníquese con el coordinador técnico de esta actividad, señor Hamid Bastani (hbastani@wmo.int).

ÍNDICE

	<i>Página</i>
PRÓLOGO	vii
PREFACIO	viii
INTRODUCCIÓN	1
Finalidad de la publicación	1
Público destinatario	2
Resumen de la iniciativa Atlas Nacionales de Recursos Energéticos Renovables de la OMM	3
MARCO TÉCNICO	4
Adquisición y análisis de datos	6
Métodos de reducción de escala	9
Proyecciones climáticas futuras	11
Evolución del marco	12
Enfoque general y países piloto	12
GUÍA PASO A PASO	14
Paso 1: Recuperación de datos	14
Paso 2: Preprocesamiento de datos	15
Paso 3: Reducción de escala	15
Paso 4: Interpolación de datos	15
Paso 5: Generación de atlas	15
Paso 6: Visualización	16
Paso 7: Incorporación de las proyecciones climáticas	48
Enseñanzas extraídas y perspectivas	54
APÉNDICE	55
A.1 Paso 1: Recuperación de datos	55
A.2 Paso 2: Preprocesamiento de datos	55
A.3 Paso 3: Reducción de escala	58
A.4 Paso 4: Interpolación de datos	63
A.5 Paso 5: Generación de atlas	64
A.6 Paso 6: Visualización	65
A.7 Paso 7: Incorporación de las proyecciones climáticas	67

PRÓLOGO

Nuestra prosperidad futura depende de la manera en que produzcamos, gestionemos y compartamos la energía en un clima cambiante. Ante el aumento de los riesgos climáticos, las sociedades dependen cada vez más de información climática precisa y útil para la adopción de decisiones que permitan garantizar el suministro de energía, proteger a las comunidades y acelerar la transición hacia las energías renovables.



La Organización Meteorológica Mundial (OMM) es desde hace mucho tiempo el principal organismo internacional especializado en meteorología, climatología, recursos hídricos y ciencias ambientales conexas. Sin embargo, nuestra misión hoy en día va más allá de las predicciones. Se trata de garantizar que la ciencia que promovemos se traduzca en servicios centrados en las personas y orientados a las necesidades de los usuarios, que sirvan de base para la adopción de decisiones, refuercen la resiliencia y promuevan el desarrollo sostenible.

Las presentes Directrices son un ejemplo de esta visión. Ofrecen un marco integral y con fundamento científico para ayudar a los Servicios Meteorológicos e Hidrológicos Nacionales (SMHN) y a las instituciones nacionales del sector energético a elaborar atlas de alta resolución de recursos eólicos, solares e hidroeléctricos. Las Directrices integran datos de reanálisis, observaciones en tierra, productos satelitales y proyecciones climáticas futuras y aplican métodos avanzados basados en datos —incluida la reducción de escala estadística basada en inteligencia artificial (IA)— para transformar esos diversos conjuntos de datos climáticos en información útil y directamente aplicable a la adopción de decisiones.

Esta publicación no es solo un manual técnico; constituye una vía para la colaboración. Refleja el principio de que ningún Miembro puede hacer frente por sí solo a los retos que plantean los riesgos climáticos. Mediante la coproducción, los datos abiertos y el desarrollo de capacidades, la iniciativa refuerza los vínculos entre las comunidades meteorológica y energética, garantizando que todas las personas —especialmente las más vulnerables— tengan acceso a la mejor información y a los mejores servicios posibles para avanzar hacia un futuro con cero emisiones netas.

Las Directrices reflejan asimismo los objetivos del *Plan Estratégico de la OMM para 2024-2027*, que aboga por atender mejor las necesidades de la sociedad, mejorar las observaciones y predicciones del sistema Tierra, impulsar los avances científicos en apoyo de los servicios y reducir las diferencias de capacidad entre los Miembros. En este contexto, los servicios climáticos centrados en las energías renovables representan una contribución tangible a la resiliencia mundial y al logro del Objetivo de Desarrollo Sostenible 7.

Quisiera expresar mi agradecimiento a los autores, colaboradores y países piloto que han participado en el diseño y la puesta a prueba de este marco. Su compromiso ejemplifica la forma en que la colaboración y una visión compartida pueden transformar la ciencia en medidas concretas.

De cara al futuro, la OMM seguirá acompañando a sus Miembros en este proceso, fomentando la innovación, fortaleciendo la colaboración y asegurando una acción coordinada entre los servicios climáticos y energéticos para empoderar a las personas, proteger nuestro planeta y construir un futuro sostenible para todos.

A handwritten signature in black ink, likely belonging to Prof. Celeste Saulo.

Prof. Celeste Saulo
Secretaria General

PREFACIO

Es para mí un gran placer presentar las presentes Directrices técnicas, elaboradas bajo los auspicios de la Comisión de Aplicaciones y Servicios Meteorológicos, Climáticos, Hidrológicos, Marinos y Medioambientales Conexos (SERCOM). Suponen un hito importante a la hora de ayudar a los Miembros a poner en marcha servicios de energías renovables y a reforzar la interacción entre la meteorología y el sector energético.



Las Directrices ofrecen un marco exhaustivo y práctico para la elaboración de atlas nacionales de recursos solares, eólicos e hidroeléctricos para energías renovables. Incluyen metodologías detalladas, requisitos de datos y procedimientos detallados que permiten a los Miembros elaborar sus propios atlas nacionales a partir de herramientas de código abierto y conjuntos de datos de acceso público. De este modo, la publicación sirve tanto de referencia metodológica como de recurso de creación de capacidad, permitiendo a los SMHN transformar datos climáticos en herramientas de apoyo a la adopción de decisiones para la comunidad energética.

En el marco de la SERCOM, este trabajo contribuye directamente al mandato de la SERCOM de orientar y coordinar la prestación de servicios en todos los ámbitos de la OMM. Contribuye a los objetivos estratégicos de la SERCOM: mejorar la prestación de servicios meteorológicos, hidrológicos y climáticos, fomentar la coproducción con los usuarios y reducir las diferencias de capacidad entre los Miembros. Las Directrices también ponen de manifiesto el enfoque colaborativo de la SERCOM: los atlas nacionales se elaboraron gracias a la colaboración entre los países piloto, los expertos y los asociados, garantizando así que el marco sea sólido, adaptable y adecuado para distintos entornos operacionales.

Quiero expresar mi reconocimiento por la dedicación y la excelencia técnica de los autores, los revisores y los países piloto, cuyas contribuciones han hecho posible este trabajo. Su colaboración refleja el compromiso común de la SERCOM de transformar la ciencia en servicios, aportando beneficios tangibles a las sociedades, las economías y los sistemas energéticos sostenibles de los que dependen.

A handwritten signature in black ink, appearing to read 'Ardhasena'.

Dr. Ardhasena Sopaheluwakan
Vice-presidente de la SERCOM

INTRODUCCIÓN

Finalidad de la publicación

Esta publicación técnica constituye un manual de usuario exhaustivo para la elaboración y la aplicación de atlas nacionales de recursos energéticos renovables (eólicos, solares e hidroeléctricos) en los Miembros de la OMM. Su objetivo principal es ofrecer una guía detallada a los Servicios Meteorológicos e Hidrológicos Nacionales (SMHN) y a otras partes interesadas pertinentes (por ejemplo, los Ministerios de Energía) para la elaboración de atlas de alta resolución a partir de datos climáticos pasados y futuros procedentes de diversas fuentes, como datos simulados, datos observacionales y datos de proyecciones.

Esta publicación se ha elaborado en el marco del proyecto Atlas de Recursos Energéticos Renovables de la OMM, definido y puesto en marcha por el equipo de la OMM Clima y Energía. El proyecto se definió a partir de las necesidades y carencias detectadas en los Miembros de la OMM mediante la encuesta sobre energía realizada por la OMM en 2022-2023¹. El trabajo fue supervisado por el Grupo de Estudio de la OMM sobre Servicios Energéticos Integrados (SG-ENE²) (2020-2024) y el Grupo de Estudio de la OMM sobre la Transición a las Energías Renovables (SG-RENE³) (2024-2027), en el marco de la Comisión de Aplicaciones y Servicios Meteorológicos, Climáticos, Hidrológicos, Marinos y Medioambientales Conexos (SERCOM), con el objetivo último de apoyar a los Miembros de la OMM en su avance hacia las emisiones netas cero y el cumplimiento de las metas del Objetivo de Desarrollo Sostenible (ODS) 7.

La publicación tiene como objetivo:

- Describir el marco técnico elaborado por la OMM para la creación de los atlas nacionales de recursos energéticos renovables, garantizando un enfoque adaptable a los distintos contextos geográficos.
- Proporcionar instrucciones detalladas sobre las técnicas de adquisición, preprocesamiento y análisis de datos, incluido el uso de conjuntos de datos de código abierto y la integración de datos observacionales locales para elaborar atlas nacionales.
- Orientar a los usuarios a lo largo del proceso de aplicación de técnicas de reducción de escala estadística para aumentar la resolución espacial y la precisión de los mapas de recursos de energías renovables.
- Orientar a los usuarios en la elaboración de atlas nacionales de recursos energéticos renovables a partir de los datos de las proyecciones climáticas de la sexta fase del Proyecto de Intercomparación de Modelos Acoplados (CMIP6).
- Explicar cómo interpretar y utilizar los atlas nacionales de recursos energéticos renovables para fundamentar la adopción de decisiones en la planificación de las energías renovables y la formulación de políticas.
- Ofrecer información sobre cómo superar los retos habituales en la elaboración de los atlas nacionales de recursos energéticos renovables, sobre la base de las experiencias de los países piloto.
- Facilitar la creación de capacidad en los SMHN mediante una sesión de capacitación grabada elaborada a partir de la presente publicación, con el fin de empoderarlos para que puedan mantener y actualizar de forma independiente sus atlas nacionales de recursos energéticos renovables a lo largo del tiempo⁴.

Al proporcionar este recurso integral, la publicación tiene por objeto mejorar el acceso a evaluaciones de alta calidad de los recursos de energías renovables basadas en datos históricos, en tiempo real y futuros procedentes de diversas fuentes, apoyando a los países en la planificación energética nacional a largo plazo, la optimización de los recursos de energías renovables, la contribución a los esfuerzos mundiales de lucha contra el cambio climático y el logro de los ODS.

¹ https://energymeteorology.info/regional_survey_dashboard/

² <https://community.wmo.int/en/governance/commission-membership/sercom/SG-Energy>

³ <https://community.wmo.int/site/knowledge-hub/governance/sercom/sercom-management-group/study-group-renewable-energy-transition>

⁴ <https://energymeteorology.info/REatlas>

Público destinatario

Este manual de usuario está destinado a un público diverso que participa en distintos aspectos de la planificación y el desarrollo de las energías renovables y la formulación de políticas sobre la materia.

Entre el público destinatario destacan, sobre todo, **los meteorólogos y el personal técnico de los SMHN**. Estos profesionales se encuentran en la primera línea de la recopilación, el análisis y la interpretación de los datos hidrometeorológicos. El manual les ofrece metodologías detalladas para la obtención y el procesamiento de datos climáticos, la aplicación de técnicas avanzadas como la reducción de escala estadística y la elaboración de mapas de alta resolución de los recursos energéticos renovables. Su objetivo es mejorar su capacidad para convertir datos hidrometeorológicos brutos en información útil para el sector energético.

Los expertos de los Ministerios de Energía y otras instituciones nacionales del sector energético constituyen otro segmento fundamental del público destinatario. Estas personas son las encargadas de definir las políticas y estrategias nacionales en materia de energía. El manual les ofrece una visión completa de cómo se pueden elaborar y aprovechar los atlas nacionales de recursos energéticos renovables para evaluar la viabilidad de los proyectos de energías renovables, optimizar la asignación de recursos y planificar la seguridad energética nacional a largo plazo sobre la base de las energías renovables. Además, les proporciona las herramientas necesarias para interpretar los atlas en el contexto de las necesidades y los objetivos energéticos nacionales.

Los especialistas y analistas expertos en políticas medioambientales también figuran entre los principales beneficiarios de este manual. Para estos profesionales, el documento sirve de puente entre los datos científicos y la formulación de políticas. Les ayuda a comprender las implicaciones medioambientales del desarrollo de las energías renovables y cómo se pueden utilizar los atlas nacionales de recursos energéticos renovables para respaldar los ODS y las estrategias de mitigación del cambio climático.

Los profesionales especializados en programación en Python para la gestión energética constituyen otro grupo destinatario importante. El manual les facilita instrucciones detalladas sobre la aplicación informática de los procesos de elaboración de los atlas nacionales de recursos energéticos renovables. Incluye fragmentos de código, explicaciones de algoritmos y las mejores prácticas para el manejo y el análisis de datos, lo que permite a estos expertos adaptar y ampliar la metodología de los atlas nacionales de recursos energéticos renovables con miras a atender necesidades nacionales o regionales específicas.

Los responsables nacionales de las decisiones y de la formulación de políticas a distintos niveles de la administración pública constituyen el público destinatario final. Aunque es posible que no estén familiarizados con los detalles técnicos, el manual ofrece resúmenes claros y concisos, así como representaciones visuales del potencial de las energías renovables. Esta información es esencial para fundamentar las decisiones relativas a las inversiones en infraestructuras energéticas, la formulación de políticas y los compromisos internacionales relacionados con las energías renovables y el cambio climático.

Por otro lado, el manual resulta de utilidad para **investigadores y estudiosos** de los campos de las energías renovables, la hidrología, la meteorología, la climatología y las ciencias ambientales. Les proporciona un marco técnico para evaluar el potencial de las energías renovables, lo que puede resultar útil para estudios comparativos, evaluaciones del impacto climático e investigaciones ulteriores en materia de planificación, instalación, explotación, mantenimiento y optimización de las energías renovables.

Por último, el manual está pensado para que puedan acceder a él **las organizaciones internacionales y las organizaciones no gubernamentales** que trabajan en el sector de las energías renovables. Estas entidades pueden utilizar libremente el manual para respaldar iniciativas de creación de capacidad y prestar asistencia técnica a los países en desarrollo en el ámbito de las energías renovables.

Con este variado público destinatario, el manual del usuario tiene por objeto crear una base común de entendimiento y colaboración entre una amplia gama de partes interesadas. Su objetivo es facilitar la comunicación entre los expertos técnicos y los encargados de la formulación de políticas, salvar la brecha entre los productores de datos y los usuarios de estos y promover un enfoque integral y holístico para el desarrollo de las energías renovables.

Resumen de la iniciativa Atlas Nacionales de Recursos Energéticos Renovables de la OMM

La iniciativa Atlas Nacionales de Recursos Energéticos Renovables es un proyecto puesto en marcha por la OMM en respuesta a las necesidades y los requisitos señalados por los Miembros de la OMM en relación con información climática de alta calidad y alta resolución sobre los recursos de energías renovables en un clima cambiante. Esta iniciativa tiene por objeto abordar los retos señalados en la encuesta sobre energía de 2022-2023 realizada por la OMM y ya mencionada, la cual puso de manifiesto que muchos SMHN cuentan con atlas nacionales obsoletos o carecen de datos climáticos esenciales —en particular, datos de proyecciones— en sus atlas actuales.

El objetivo principal de la iniciativa era desarrollar conjuntamente un marco técnico integral, unas directrices detalladas y una herramienta práctica, escalable y de acceso abierto para la elaboración sistemática de atlas nacionales de recursos eólicos, solares e hidroeléctricos. La iniciativa fue diseñada y puesta en marcha por el equipo de la OMM Clima y Energía en 2024 siguiendo un enfoque ascendente, como complemento a los atlas mundiales de enfoque descendente elaborados por el Banco Mundial⁵ y la Agencia Internacional de Energías Renovables (IRENA)⁶. El objetivo es dotar a los SMHN de todo el mundo de los recursos necesarios, incluidos los datos existentes en los atlas mundiales, para que puedan elaborar y mantener atlas nacionales de alta resolución que incorporen datos actuales y proyecciones climáticas futuras adaptados a sus necesidades y requisitos nacionales. Una característica fundamental de la iniciativa Atlas Nacionales de Recursos Energéticos Renovables es la atención que presta a la elaboración de atlas con una resolución espacial de 4 km o menos. Este alto nivel de detalle es fundamental para evaluar con precisión el potencial de las energías renovables a escala local y regional, permitiendo así una planificación y una adopción de decisiones más precisas en materia de desarrollo de las energías renovables.

La iniciativa ayuda a los países a avanzar por la senda trazada en el 28º período de sesiones de la Conferencia de las Partes en la Convención Marco de las Naciones Unidas sobre el Cambio Climático, que incluye triplicar la capacidad de las energías renovables y duplicar la eficiencia energética para 2030, con el objetivo final de alcanzar las cero emisiones netas para 2050. Al proporcionar información precisa, detallada y actualizada sobre los recursos de energía renovable, la iniciativa Atlas Nacionales de Recursos Energéticos Renovables ayuda directamente a los países a optimizar sus estrategias relativas a las energías renovables y a contribuir a esos objetivos climáticos mundiales. Uno de los principales aspectos innovadores de esta iniciativa es su enfoque colaborativo. En la fase inicial del proyecto, en 2024, la OMM colaboró estrechamente con los SMHN de cuatro países piloto (Chile, Costa Rica, la República Islámica del Irán y Malawi), así como con las partes interesadas de los sectores energéticos nacionales, implicándolas activamente en el desarrollo y la aplicación del marco de la iniciativa. Este modelo de coproducción garantizó que los atlas resultantes no solo fueran sólidos desde el punto de vista científico, sino también prácticos y adecuados a las necesidades de los usuarios finales nacionales.

La iniciativa Atlas Nacionales de Recursos Energéticos Renovables se ha diseñado teniendo en cuenta su escalabilidad y aplicabilidad a nivel mundial. La visión a largo plazo de la iniciativa, que se puso en marcha con cuatro países piloto en 2024 y se amplió a otros cuatro en 2025 durante la segunda fase, consiste en incorporar progresivamente a más Miembros de la OMM en las

⁵ <https://globalatlas.info/map> y <https://globalwindatlas.info/es/>.

⁶ <https://globalatlas.irena.org/workspace>

distintas fases del proceso de desarrollo. El objetivo ambicioso es dotar a todos los Miembros de la OMM de atlas nacionales de recursos energéticos renovables actualizados y de alta resolución de aquí a finales de 2027.

Otro aspecto importante de la iniciativa es su compromiso con el acceso abierto a los códigos y materiales, así como a las sesiones de capacitación. La metodología para elaborar atlas nacionales de recursos energéticos renovables de alta resolución se puede consultar de forma gratuita en el Portal de Energía y Meteorología de la OMM.⁷

La iniciativa también hace hincapié en la integración de los datos locales con los conjuntos de datos mundiales. Se alienta a los países a que incorporen sus propios datos de seguimiento para mejorar la calidad y la pertinencia de sus atlas nacionales de recursos energéticos renovables. No obstante, aun sin disponibilidad de datos locales, los países pueden utilizar los datos simulados disponibles para elaborar sus propios atlas de recursos energéticos renovables, lo que garantiza que ningún país se quede rezagado en este primer paso crucial hacia una planificación energética estratégica a largo plazo y la transición energética con emisiones netas cero.

MARCO TÉCNICO

El marco técnico para el desarrollo de los atlas nacionales de recursos energéticos renovables está concebido para ser exhaustivo, flexible, escalable y adaptable a diversos contextos geográficos y tecnológicos. Se ha elaborado a partir de dos enfoques temporales distintos para dar respuesta a diferentes necesidades de planificación. La base principal de los atlas consiste en el análisis de datos históricos, que combina datos del reanálisis de ERA5-Land y datos obtenidos por satélite con observaciones en tierra procedentes de redes nacionales de vigilancia, cuando están disponibles. Este análisis histórico se somete a procedimientos de reducción de escala estadística a fin de alcanzar la alta resolución espacial (4 km o menos) necesaria para la evaluación detallada de los recursos y la planificación de proyectos. Para analizar el impacto del cambio climático en el potencial de los recursos de energía renovable, el marco incorpora proyecciones climáticas de dos trayectorias socioeconómicas compartidas (SSP), concretamente la SSP3-7,0 y la SSP5-8,5, procedentes de un único modelo CMIP6, el CNRM-ESM2-1 (versión r1i1p1f2). La combinación actual de análisis históricos de alta resolución y proyecciones preliminares prospectivas convierte a los atlas en herramientas valiosas, sobre todo para la planificación inmediata de proyectos, y está previsto que las capacidades de simulación de escenarios futuros se amplíen en fases de desarrollo posteriores.

Las figuras 1 y 2 muestran ilustraciones esquemáticas de los marcos aplicados para elaborar atlas de energía solar y eólica y atlas de energía hidroeléctrica, respectivamente. En cada figura se incluyen los detalles del enfoque tanto para las condiciones climáticas actuales como para las futuras. En los apartados siguientes se presentan y analizan pormenorizadamente las distintas fases del marco. En concreto, en la sección sobre adquisición y análisis de datos se presentan los datos de entrada, el método de control de calidad aplicado y la técnica de establecimiento de cuadrículas basada en la ponderación de la distancia inversa. En la sección sobre los métodos de reducción de escala se describen los aspectos de este proceso. Por último, en la sección dedicada a las proyecciones climáticas futuras se incluye información sobre cómo se aplica la metodología general para estimar el efecto del cambio climático.

⁷ <https://energymeteorology.info/REatlas/>




Figura 1. Ilustración esquemática del marco propuesto para elaborar atlas nacionales de recursos eólicos y solares

Nota: MDE – modelo digital de elevación; PMC: perceptrón multicapa.




Gráfico 2. Ilustración esquemática del marco propuesto para elaborar atlas nacionales de recursos hidroeléctricos

Adquisición y análisis de datos

El marco de los atlas nacionales de recursos energéticos renovables se basa en fuentes de datos fiables y accesibles. Las fuentes de los atlas nacionales de recursos solares, eólicos e hidroeléctricos se enumeran en los cuadros 1 a 3, respectivamente. En cada cuadro se especifican las variables objetivo y las variables explicativas utilizadas en el enfoque de reducción de escala mediante aprendizaje automático.

Cuadro 1. Fuentes de datos meteorológicos y parámetros necesarios para generar un atlas nacional de recursos solares

Atlas de energía solar		
Fuente de datos	Variable	Resolución espacial
Variable objetivo		
ERA5-LAND (quinta generación del modelo de reanálisis del ECMWF – Tierra)	Flujo descendente de radiación de onda corta en superficie	9 km
Variables predictoras		
	Temperatura en superficie	
	Nubosidad total	

<i>Atlas de energía solar</i>		
<i>Fuente de datos</i>	<i>Variable</i>	<i>Resolución espacial</i>
GLO-90 (datos del modelo digital de elevación de 90 m de Copernicus)	Altitud	90 m
	Aspecto	
	Pendientes	
SARAH-3 (conjunto de datos de radiación en superficie)	Irradiación solar	5 km
Clima futuro		
CMIP6 (sexta fase del CMIP)	Flujo descendente de radiación de onda corta en superficie	100 km
	Temperatura en superficie	

Cuadro 2. Fuentes de datos meteorológicos y parámetros necesarios para generar un atlas nacional de recursos eólicos

Atlas de energía eólica		
Fuente de datos	Variable	Resolución espacial
Variables objetivo		
ERAS-LAND (quinta generación del modelo de reanálisis del ECMWF – Tierra)	Componente U del viento a 10 m	9 km
	Componente V del viento a 10 m	
Variables predictoras		
GLO-90 (datos del modelo digital de elevación de 90 m de Copernicus)	Altitud	90 m
	Aspecto	
	Pendiente	
Clima futuro		
CMIP6 (sexta fase del CMIP)	Componente U del viento a 10 m	100 km
	Componente V del viento a 10 m	

Cuadro 3. Fuentes de datos meteorológicos y parámetros necesarios para generar un atlas nacional de recursos hidroeléctricos

<i>Atlas de energía hidroeléctrica</i>		
<i>Fuente de datos</i>	<i>Variable</i>	<i>Resolución espacial</i>
ERA5-LAND (quinta generación del modelo de reanálisis del ECMWF – Tierra)	Precipitación total	9 km
GloFAS (Sistema mundial de concienciación sobre inundaciones)	Caudal	5 km
HydroBASINS (producto de la base de datos HydroSHEDS)	Límites de las cuencas hidrográficas	Subdivisiones de nivel 5 y nivel 12 de la cuenca principal en las cuencas secundarias de los afluentes
	Red fluvial	
CMIP6 (sexta fase del CMIP)	Caudal	100 km

La lista de conjuntos de datos puede ampliarse aún más con otras fuentes de datos mencionadas anteriormente, como los conjuntos de datos del Banco Mundial y de la IRENA. La disponibilidad de estos datos adicionales depende del país en cuestión. Además, siempre que sea posible, el

marco integra las observaciones de las estaciones de la red de SMHN para mejorar la precisión a nivel local. Dichos datos se someten a un preprocesamiento en dos fases para garantizar su calidad y su utilidad:

- Control de calidad: se aplican procesos básicos de control de calidad, esto es, se eliminan los valores atípicos que se salen de los rangos estándar, así como los intervalos temporales anómalos en las series temporales (como los valores repetidos), y no se tienen en cuenta en el análisis los datos de estaciones con menos de dos años de registros y en las que falte más del 70 % de los datos.
- Agregación temporal: los datos se agregan a una escala temporal adecuada mediante un promedio diario, pero el usuario puede modificar la escala temporal de la agregación según sus necesidades.

Los datos de observación *in situ* se interpolan espacialmente mediante el método de ponderación de la distancia inversa. A continuación se describe dicho método a partir de la notación utilizada por Kalnay (2003).⁸ El objetivo es hallar la estimación óptima (campo de análisis: x_a) a partir de un campo de referencia (x_b) disponible en puntos de la cuadrícula en dos o más dimensiones, y un conjunto de n observaciones y_o en puntos espaciados de forma irregular dentro del dominio. En nuestro caso, la estimación óptima será el mapa final de radiación solar, viento o caudal (es decir, $x_a = SOL_a$), el campo de referencia será el mapa interpolado de las mediciones de las estaciones (es decir, $x_b = SOL_b$), y las observaciones serán los datos de reanálisis o de modelos ($y_o = SOL_{Model}$). A continuación, debemos hallar la solución para:

$$SOL_a = SOL_g + W(SOL_{Model} - H(SOL_g)) - E_a \quad (1)$$

donde σ_a es la incertidumbre del análisis, el campo de referencia es un vector de longitud p , la matriz de ganancia W tiene dimensión (p, n) y el operador H transforma el campo de referencia en la primera aproximación de las observaciones. El reto consiste en hallar el valor óptimo de la matriz W para minimizar σ_a . Suponiendo que los errores en el campo de referencia y en las observaciones no estén sesgados y que los errores del campo de referencia no estén correlacionados con los errores de observación, el operador de ganancia puede expresarse como sigue:

$$W = BH(R + HBH) \quad (2)$$

donde B y R son, respectivamente, la covarianza de error del campo de referencia (de tamaño $p \times p$) y las matrices de covarianza de error de observación (de tamaño $n \times n$), respectivamente. Si los errores del campo de referencia en distintos puntos de la cuadrícula no están correlacionados y los errores de observación no están correlacionados entre sí, estas dos matrices pasan a ser diagonales y la solución de la ecuación viene dada simplemente por una media ponderada del campo de referencia y las observaciones, que en nuestro caso son los mapas interpolados en superficie y los datos de los modelos:

$$SOL_a = \frac{\frac{SOL_g}{\sigma_g^2} + \frac{SOL_{Model}}{\sigma_{Model}^2}}{\frac{1}{\sigma_g^2} + \frac{1}{\sigma_{Model}^2}} \quad (3)$$

donde las dos σ son las dos varianzas. Por consiguiente, el conjunto de datos final se asimila en el campo de referencia de reanálisis mediante una media ponderada que depende del inverso de la distancia entre la estación más cercana y el punto de la cuadrícula considerado.

⁸ Kalnay, E. *Atmospheric Modeling, Data Assimilation and Predictability*. Cambridge: Cambridge University Press, 2003.

Cuando la red incluye varias estaciones, los reanálisis se ajustan para que coincidan con las observaciones. Por el contrario, en zonas remotas con un escaso número de estaciones, la influencia de las observaciones resulta insignificante. El enfoque es lo suficientemente flexible como para aplicarse a redes con cualquier número de estaciones. El objetivo es utilizar el mayor número posible de observaciones y calibrar el procedimiento de asimilación basándose en los datos disponibles. No es posible establecer un número mínimo de estaciones para integrar las observaciones, dado que esa cifra dependería en gran medida del contexto geográfico. Por ejemplo, en terrenos uniformes, puede ser necesario un número relativamente mayor de estaciones. El ajuste del método para adaptarlo a las observaciones disponibles sin limitaciones a priori es una decisión pragmática destinada a maximizar la integración de los datos de las estaciones en tierra.

Métodos de reducción de escala

Como se muestra en las figuras 1 y 2, el método contempla dos enfoques diferentes de reducción de escala: uno para la energía solar y eólica y otro para la generación hidroeléctrica. En los siguientes apartados se describen ambos enfoques con detalle. Cabe aclarar que ambos métodos tienen carácter ilustrativo y no son excluyentes. En la bibliografía se recogen otras alternativas válidas que los usuarios pueden tener en cuenta. El presente trabajo tiene como objetivo proporcionar a los SMHN y a otras partes interesadas pertinentes herramientas prácticas que puedan utilizarse, adaptarse y optimizarse en función de las necesidades específicas.

Reducción de escala para atlas de energía solar y eólica

En lo que respecta a la producción de energía solar y eólica, se utiliza un método de reducción de escala estadística sencillo pero eficaz, que requiere relativamente pocos recursos computacionales y datos adicionales. El enfoque se basa en el algoritmo de aprendizaje automático denominado "perceptrón multicapa". Los perceptrones multicapa son un tipo de red neuronal de propagación hacia adelante, especialmente adecuada para la reducción de escala debido a su capacidad para modelar relaciones complejas y no lineales entre los datos de entrada y de salida. Aplicamos los perceptrones multicapa mediante el paquete scikit-learn para Python, conocido por la ejecución eficiente de algoritmos y la interfaz intuitiva que ofrece en comparación con otros marcos de aprendizaje automático.

El perceptrón multicapa está concebido como un método de referencia destinado a sentar las bases para futuras mejoras en función de las necesidades y capacidades de los SMHN. El aprendizaje automático se utiliza cada vez más con fines de reducción de escala. De hecho, su capacidad para deducir relaciones no lineales a partir de un gran volumen de datos lo hace especialmente eficaz para sistemas complejos como el clima. Se están utilizando varios métodos, que valdría la pena probar también en este contexto. Por ejemplo, Random Forest es un algoritmo rápido y robusto que ofrece buenos resultados para este fin.⁹ A pesar de sus elevadas necesidades computacionales, el aprendizaje profundo ofrece perspectivas halagüeñas para los estudios sobre el cambio climático debido a su capacidad de extrapolación.¹⁰ Las técnicas de aprendizaje automático pueden condicionarse mediante leyes físicas imponiendo, por ejemplo, la conservación de la masa y la energía. Este método mejora el rendimiento predictivo en diferentes estructuras de aprendizaje profundo con diversos conjuntos de datos climáticos.¹¹ Al margen de los métodos de aprendizaje automático, la reducción de escala también se puede realizar de forma dinámica. Cabe mencionar métodos consolidados, como las simulaciones numéricas de alta resolución para la energía eólica y las técnicas de inversión de modelos físicos basadas en datos obtenidos por satélite para la energía solar. En lo que respecta a las proyecciones climáticas, el Experimento coordinado sobre reducción de escala de modelos climáticos regionales (CORDEX) lleva más de 15 años trabajando en la reducción numérica de

⁹ <https://opentopography.org/start>

¹⁰ <https://global-flood.emergency.copernicus.eu/>

¹¹ https://data.hydrosheds.org/file/technical-documentation/HydroBASINS_TechDoc_v1c.pdf

la escala de la información de los modelos climáticos globales (MCG). Conviene aclarar que el método propuesto tiene por objeto ofrecer una solución fácil de aplicar a los países piloto, más que establecer una norma única para un sector tan complejo como el de las energías renovables.

En el caso de los atlas nacionales de recursos solares y eólicos, las variables utilizadas para el proceso de entrenamiento son las siguientes:

- radiación solar incidente: latitud, longitud, orientación, altitud, fracción total de nubosidad;
- velocidad y dirección del viento (a 10 o 100 m): latitud, longitud, orientación, altitud.

El algoritmo de entrenamiento se basa en las características morfológicas del terreno, ya que muchas variables climáticas a nivel del suelo se ven muy influidas por la altitud y la orientación del terreno. Dado que las variables objetivo se derivan del modelo ERA5-Land, el conjunto de datos de entrenamiento incluye características del terreno extraídas del mismo modelo para garantizar la coherencia (en concreto, datos orográficos como la altitud y la orientación).

La orografía en ERA5-Land se deriva del geopotencial de superficie, que sirve como indicador de la altitud. Al dividir el geopotencial de superficie por la constante de aceleración gravitatoria, lo convertimos en un modelo digital de elevación, que posteriormente se utiliza para calcular otras características relacionadas con la orografía, como la orientación del terreno (la orientación de la pendiente en grados respecto del norte). La resolución espacial de estos elementos de ERA5-Land es de 0,1°, es decir, aproximadamente 11 km.

A continuación, el modelo, entrenado con datos de ERA5-Land, se utiliza para predecir valores de alta resolución. Para ello, introducimos en el modelo el conjunto de datos del GLO-90, modelo digital de elevación mundial de acceso libre mantenido por Copernicus. El GLO-90 proporciona datos de altitud directamente, que procesamos posteriormente para calcular la orientación. Los resultados obtenidos tras la reducción de escala alcanzan una resolución espacial de 90 m. Este enfoque se aplica a la radiación solar incidente en la superficie, la velocidad del viento y la dirección del viento.

Reducción de escala para atlas de generación hidroeléctrica

Para la reducción de escala del caudal en los atlas nacionales de recursos hidroeléctricos se utilizó un enfoque basado en cuencas y cuencas secundarias fluviales a diferentes escalas. El conjunto de datos de partida es GloFAS, conjunto de datos en cuadrícula que proporciona datos sobre el caudal de los ríos (m^3/s) en celdas de cuadrícula con una resolución de 0,05° (aproximadamente 5,5 km). Si bien este conjunto de datos permite comprender los patrones del caudal, su resolución espacial sigue siendo demasiado baja para describir con precisión el caudal en distintos tramos de un río, ya que características fluviales como el ancho y el trazado del río se sitúan muy por debajo de la resolución de la cuadrícula. Incluso aplicando una metodología de reducción de escala como la utilizada para los atlas nacionales de recursos solares y eólicos, la resolución más alta (del orden de unos 100 metros) seguiría siendo demasiado baja para describir las características físicas de un río. Además, las cuadrículas uniformes, como la cuadrícula nativa de GloFAS o la resultante de la reducción de escala, no se corresponden con entidades hidrológicas relevantes, como cuencas o cuencas secundarias

Por estos motivos, hemos procesado los datos de GloFAS a escala de cuencas y cuencas secundarias fluviales, con el fin de proporcionar datos sobre el caudal de los ríos en unidades hidrológicamente relevantes. Recuperamos los límites de las cuencas hidrográficas a partir de HydroBASINS, conjunto de datos que proporciona límites de cuencas hidrográficas coherentes y jerárquicos a escala mundial. En esta representación, el nivel 0 corresponde a la extensión completa de la cuenca de drenaje del río, que normalmente incluye el río principal y todos sus afluentes desde la naciente hasta la desembocadura, mientras que los niveles 1 a 12 representan subdivisiones de la cuenca principal en las cuencas secundarias de los afluentes, ofreciendo cada nivel sucesivo un grado de detalle mayor (véase la figura 3, donde “Pfafstetter” se refiere al método jerárquico de codificación e identificación de cuencas y cuencas secundarias fluviales).




Figura 3. Sistema de Pfafstetter para la codificación hidrológica de cuencas fluviales

Para generar los atlas nacionales de recursos hidroeléctricos, es necesario aplicar los dos modos siguientes:

- A nivel nacional: el caudal medio de las principales cuencas hidrográficas situadas dentro de las fronteras nacionales, que suele corresponder al nivel 5 de HydroBASINS, dependiendo del tamaño del país.
- A nivel regional: proporciona información detallada sobre las cuencas secundarias de nivel 12 dentro de una región seleccionada, la resolución más detallada de HydroBASINS. El tamaño de las cuencas secundarias a este nivel es variable, ya que depende de las características hidrológicas de los afluentes más pequeños.

La información a nivel nacional tiene por objeto ofrecer, de un vistazo, la distribución del potencial hidroeléctrico en un país, destacando los ríos con mayor caudal. Una vez detectada una zona de interés, la información a nivel regional ayuda a identificar las zonas donde se registran máximos locales de caudal, proporcionando indicios preliminares fundamentales del potencial hidroeléctrico.

La información, tanto a nivel nacional como regional, se obtiene mediante operaciones estadísticas zonales del sistema de información geográfica (SIG). Para garantizar la interoperabilidad y facilitar la aplicación, utilizamos los paquetes de Python Rasterstats y Xarray para cargar los datos de GloFAS, superponer las cuencas de nivel 5 o nivel 12 y calcular el caudal dentro de cada cuenca fluvial.

Proyecciones climáticas futuras

Las estimaciones de los recursos de energías renovables para las condiciones climáticas futuras se basan en datos de los MCG del CMIP6¹². El enfoque comprende dos tipos de experimentos:

¹² <https://wcrp-cmip.org/cmip-phases/cmip6/>

- Experimento histórico: abarca el período para el que se dispone de observaciones climáticas modernas y muestra el rendimiento de los MCG en lo que respecta al clima del pasado.
- Experimento de proyección climática: sigue las trayectorias combinadas de las SSP; en concreto, nos centramos en la SSP3-7,0 y la SSP5-8,5. Los escenarios de las SSP proporcionan distintas trayectorias del forzamiento del clima futuro para el período 2015-2100.

Se seleccionó el modelo CNRM-ESM2-1 (versión r1i1p1f2) porque proporciona todas las variables necesarias, incluidos los datos de caudal, que no están disponibles de forma sistemática en todos los modelos del CMIP6.¹³ Cabe señalar que un análisis exhaustivo de la incertidumbre que incorpore múltiples modelos excede el alcance de la fase actual del proyecto. El desarrollo futuro de los atlas ampliará este análisis para incluir múltiples modelos del CMIP6 y una evaluación exhaustiva de las incertidumbres asociadas a los escenarios, proporcionando una base más sólida para la adopción de decisiones de planificación a largo plazo.

Tanto los productos históricos como las proyecciones se sometieron a reducción de escala mediante el mismo procedimiento descrito en las secciones anteriores para las condiciones climáticas actuales. En lo que respecta a la energía solar y eólica, interpolamos los datos del CMIP6 sobre la cuadrícula de alta resolución del modelo digital de elevación y, posteriormente, aplicamos el perceptón multicapa para refinar la resolución espacial de la velocidad del viento y de la irradiancia horizontal global. En lo tocante a la generación de energía hidroeléctrica, utilizamos la evaluación hidrológica a escala de cuenca para estimar el caudal con alta resolución. A continuación, calculamos la diferencia entre cada escenario y el experimento histórico para obtener una variación prevista. Esta variación se superpuso a los mapas de alta resolución obtenidos al finalizar la aplicación del método para las condiciones climáticas actuales.

Evolución del marco

El marco presentado en este manual operativo se basa en los resultados de la primera fase del proyecto de la OMM Atlas Nacionales de Recursos Energéticos Renovables (2024). El marco se siguió perfeccionando durante la segunda fase del proyecto (2025), al incorporar los dos aspectos principales siguientes:

- las fuentes de datos de entrada se han ampliado a fin de incorporar observaciones de la Tierra procedentes del conjunto de datos SARA-3¹⁴ para los atlas solares.
- se ha revisado el enfoque aplicado a las proyecciones climáticas futuras con el fin de utilizar el mismo método de reducción de escala que se emplea para los datos históricos en dos escenarios climáticos.

Enfoque general y países piloto

La elaboración de los atlas nacionales de recursos energéticos renovables sigue un enfoque colaborativo e iterativo, haciendo hincapié en la coproducción con los SMHN, los ministerios competentes (como los de energía, medio ambiente y planificación) y otras entidades gubernamentales clave, a fin de garantizar la pertinencia, la utilidad y la sostenibilidad de los atlas resultantes. Esta participación de múltiples partes interesadas garantiza la coherencia con las prioridades nacionales y los marcos institucionales. El enfoque se estructura en torno al modelo del doble diamante, que comprende cuatro fases clave: descubrimiento, definición, desarrollo y ejecución.

El proceso comienza con un estudio inicial para evaluar la situación actual de los datos sobre energías renovables y los atlas en cada país participante. A continuación, se celebran reuniones por separado con cada SMHN para analizar las necesidades, los retos y las expectativas específicos. Las reuniones quincenales con todos los SMHN participantes garantizan una interacción y un intercambio de opiniones continuos a lo largo de todo el proyecto.

¹³ <https://www.umr-cnrm.fr/cmip6/data/tdb.pdf>

¹⁴ <https://user.eumetsat.int/catalogue/EO:EUM:DAT:0863>

Esta estrategia de coproducción permite adaptar la metodología de los atlas nacionales de recursos energéticos renovables a las necesidades y capacidades específicas de cada país, manteniendo al mismo tiempo un enfoque básico normalizado. También facilita la transferencia de conocimientos y la creación de capacidad, lo que permite a los SMHN mantener y actualizar de manera independiente sus atlas en el futuro.

El proyecto se puso en marcha en 2024 en cuatro países piloto, cada uno de ellos centrado en un recurso energético renovable diferente. A continuación se ofrece una breve descripción de cada caso. Las actividades de seguimiento dieron lugar a la elaboración de atlas nacionales de recursos energéticos renovables para Croacia, la República Unida de Tanzania y Cuba en 2025. En los próximos años se sumarán más países.

Energía solar: Chile y la República Islámica del Irán

Chile

El atlas de energía solar de Chile se elaboró en colaboración con la Dirección Meteorológica de Chile (DMC) y el Ministerio de Energía de Chile. Aunque Chile no contaba con un atlas nacional de energía solar, la DMC llevaba ya mucho tiempo realizando seguimientos y archivando parámetros relacionados con la energía solar. Para este proyecto se utilizó una red de unas 37 estaciones operativamente disponibles para la recopilación de datos de irradiancia horizontal global, 35 estaciones de registro de nubosidad y alrededor de 150 estaciones de medición de temperatura. La duración media de estas series temporales es de aproximadamente 20 años, lo que proporciona una base sólida para la elaboración de un atlas solar integral.

República Islámica del Irán

La elaboración del atlas de energía solar de la República Islámica del Irán se llevó a cabo en colaboración con la Organización Meteorológica de la República Islámica del Irán y la Organización de Energías Renovables y Eficiencia Energética de este país. Aunque la República Islámica del Irán utilizaba anteriormente un atlas solar comercial, este presentaba limitaciones en cuanto a resolución, actualizaciones y representación de las condiciones locales. El proyecto contó con una amplia red de alrededor de 50 estaciones de observación que registraban diariamente la irradiancia horizontal global, además de 800 estaciones que monitoreaban la temperatura y la nubosidad. El resultado fue la elaboración de un atlas de mayor resolución capaz de estimar el potencial de energía solar por píxel, superando las limitaciones anteriores.

Energía eólica: Costa Rica

El atlas de energía eólica de Costa Rica se elaboró en colaboración con el Instituto Costarricense de Electricidad (ICE) y el Instituto Meteorológico Nacional de Costa Rica. Costa Rica está centrando sus esfuerzos en diversificar su cartera de energías renovables, pero los estudios previos sobre energía eólica se limitaban a la región noroccidental y el país carecía de un mapa o atlas nacional integral de recursos eólicos. El proyecto utilizó una red de 45 estaciones de medición del viento repartidas por todo el país, cuyas series temporales tenían una duración media de 20 años. La mayoría de las estaciones registran la velocidad del viento a 10 m de altura, y algunas ofrecen perfiles verticales del viento. Además, el ICE tuvo acceso a datos de reanálisis locales correspondientes al período comprendido entre 1970 y 2019 mediante el modelo Weather Research and Forecasting (WRF). La elaboración de un atlas eólico nacional ayudará a Costa Rica a integrar la energía eólica de forma más eficaz en su canasta de energía nacional.

Energía hidroeléctrica: Malawi

El atlas de energía hidroeléctrica de Malawi se elaboró en colaboración con el Departamento de Cambio Climático y Servicios Meteorológicos de Malawi. La energía hidroeléctrica es la principal fuente de energía del país, lo que hace que este atlas sea especialmente importante.

El proyecto se valió de una amplia red de estaciones meteorológicas, que incluía 22 estaciones meteorológicas completas, 21 estaciones agrometeorológicas auxiliares, más de 80 estaciones meteorológicas automáticas y más de 700 estaciones pluviométricas. Muchas de estas estaciones contaban con datos que abarcaban un período de entre 30 y 60 años, y algunos registros se remontaban a la década de 1890. La elaboración de un atlas hidroeléctrico integral aprovechó este amplio conjunto de datos para proporcionar información valiosa destinada a la planificación y el desarrollo hidroeléctricos en Malawi.

Estos cuatro países piloto representan contextos geográficos, climáticos y tecnológicos diversos, lo que permitió someter el marco de los atlas nacionales de recursos energéticos renovables a pruebas exhaustivas y perfeccionarlo. Las experiencias y enseñanzas extraídas de estos proyectos piloto se han utilizado para desarrollar la iniciativa Atlas Nacionales de Recursos Energéticos Renovables, que actualmente se está ampliando a otros Miembros de la OMM. Esta ampliación sigue en curso en 2025, con la inclusión de Mozambique, la República Unida de Tanzania, Cuba y Croacia.

GUÍA PASO A PASO

La elaboración de los atlas nacionales de recursos energéticos renovables comprende las etapas siguientes. Para consultar los códigos de Python correspondientes, véase el anexo. Todos los códigos también se pueden consultar en línea en la página web del proyecto Atlas Nacional de Recursos Renovables Energéticos de la OMM.¹⁵

Paso 1: Recuperación de datos

Para descargar los datos necesarios mediante la interfaz de programación de aplicaciones (API) de la Copernicus Climate Data Store (CDS) en Python, hay que seguir los siguientes pasos.

a) Creación de una cuenta:

- Visite la página web de la CDS en <https://cds.climate.copernicus.eu/>.
- Cree una cuenta cumplimentando los datos necesarios, como su dirección de correo electrónico, nombre de usuario y contraseña.
- Revise su bandeja de entrada para localizar el correo electrónico de confirmación enviado por la CDS y active su cuenta mediante el enlace remitido a su dirección de correo electrónico.

b) Acceso a la API de la CDS:

- Inicie sesión en su cuenta de la CDS.
- Una vez que haya iniciado sesión, vaya a la sección "API key" dentro de su perfil de usuario. Esta sección suele encontrarse en la configuración de la cuenta o en el área de perfil.
- Copie su clave API única. Esta clave se utilizará como forma de autenticación al realizar solicitudes a la API de la CDS.

c) Instalación del cliente de la API de la CDS:

- Asegúrese de que Python y pip (el instalador de paquetes de Python) estén correctamente instalados en su sistema.
- Para interactuar con la API de la CDS mediante Python, es necesario instalar la biblioteca cliente de la API de la CDS. Abra la interfaz de línea de comandos y ejecute el siguiente comando: *pip install cdsapi*

¹⁵ <https://energymeteorology.info/REatlas/>

- d) Redacción de una secuencia de comandos en Python para consultar el cliente de la API de la CDS:
- Cree un nuevo archivo de secuencia de comandos en Python. Esta secuencia de comandos contendrá el código necesario para descargar datos de ERA5-Land mediante la API de la CDS. Para ver los códigos pertinentes en Python, consulte la sección A.1 del anexo (Paso 1: Recuperación de datos).

Paso 2: Preprocesamiento de datos

Los datos brutos se someten a varias fases de preprocesamiento para garantizar su calidad y su utilidad. El control de calidad incluye la detección de anomalías, la verificación de la coherencia de los datos, la validación de los datos de las estaciones, la conversión de las unidades de medida y la identificación y corrección de valores atípicos sobre la base de valores climatológicos. La agregación temporal a escalas temporales pertinentes (por ejemplo, horaria, diaria o mensual) comprende la normalización de los intervalos temporales, la integración de las series temporales de datos de las estaciones y la armonización de las resoluciones temporales de los datos de reanálisis y de las estaciones. La interpolación espacial de los datos solares y eólicos se centra en la normalización de las resoluciones, la interpolación de los datos de las estaciones y la generación de superficies continuas de corrección. Por el contrario, el análisis espacial de los datos sobre energía hidroeléctrica consiste en la delimitación de macrocuencas. En el caso de los datos sobre el viento, también se realiza el cálculo de la velocidad y la dirección del viento a partir de los componentes U y V. Para ver los códigos pertinentes en Python, consulte la sección A.2 del anexo (Paso 2: Preprocesamiento de datos).

Paso 3: Reducción de escala

En el caso de los datos eólicos y solares, se aplica un método estadístico de reducción de escala mediante aprendizaje automático y basado en perceptrones multicapa con el fin de afinar la resolución espacial de los datos de ERA5-Land. Este enfoque también tiene en cuenta la topografía y la rugosidad de la superficie, lo que permite crear mapas de recursos de alta resolución que reflejen las variaciones locales. En el caso de los atlas nacionales de recursos hidroeléctricos, se aplica un enfoque multiescala para agregar el caudal dentro de los límites de las cuencas hidrográficas, teniendo en cuenta la variabilidad espacial y temporal. Trabajamos tanto en el nivel 5 de HydroBASINS como en el nivel 12, con cuencas secundarias detalladas. Para ver los códigos pertinentes en Python, consulte la sección A.3 del anexo (Paso 3: Reducción de escala).

Paso 4: Interpolación de datos

El método de ponderación de la distancia inversa, explicado anteriormente, se aplica a los datos de las estaciones meteorológicas de la red para obtener la cuadrícula de alta resolución resultante al final del proceso de reducción de escala. Este paso permite al usuario asimilar observaciones *in situ* en los atlas nacionales de recursos energéticos renovables, haciendo que los atlas sean más representativos de las condiciones climáticas locales. Para ver los códigos pertinentes en Python, consulte la sección A.4 del anexo (Paso 4: Interpolación de datos)..

Paso 5: Generación de atlas

El conjunto de los datos de ponderación de la distancia inversa derivado de las estaciones meteorológicas se integra con el conjunto de datos de reducción de escala mediante la ponderación de cada conjunto de datos sobre la base de las incertidumbres estimadas. Los resultados se entregan en formatos NetCDF y GeoTIFF para garantizar un fácil acceso. NetCDF ofrece un almacenamiento eficiente de datos científicos con metadatos integrados,

mientras que GeoTIFF incorpora información de georreferenciación esencial para los análisis de SIG. Para ver los códigos pertinentes en Python, consulte la sección A.5 del anexo (Paso 5: Generación de atlas).

Paso 6: Visualización


Este paso permite al usuario visualizar las siguientes variables:

- atlas nacionales de recursos solares: medias anuales y mensuales de la irradiancia horizontal global expresadas en kWh/m²/día;
- atlas nacionales de recursos eólicos: medias anuales y mensuales de la velocidad del viento (m/s) y la dirección del viento (ángulo);
- atlas nacionales de recursos hidroeléctricos: caudal medio a nivel nacional y regional.

Se tienen muy en cuenta los principios cartográficos para crear mapas precisos e informativos. Se utilizan combinaciones de colores y enfoques de escalado personalizados para resaltar variaciones significativas, manteniendo al mismo tiempo la legibilidad y la claridad. Los gráficos incorporan elementos geográficos, como líneas de costa, fronteras, ríos y lagos, para contextualizar los datos. Además, se incluyen cuadrículas y barras de color dinámicas para facilitar una interpretación precisa. Para ver los códigos pertinentes en Python, consulte la sección A.6 del anexo (Paso 6: Visualización). En las páginas siguientes figuran los mapas generados a lo largo de las distintas fases del proyecto de atlas nacionales de recursos energéticos renovables, comenzando por las fases iniciales y continuando con los estudios de caso a medida que el proyecto avanzaba. Cada ejemplo incluye información sobre los datos de código abierto y las observaciones *in situ* que se han utilizado para elaborar los mapas de alta resolución.

6.1 **Chile (atlas de energía solar)**


Radiación (solar) de onda corta incidente en superficie



Atlas de energía solar de Chile	
Recurso cartografiado	Radiación de onda corta incidente en superficie
Unidades de los datos	kWh/m²/día
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	37
Período que abarcan los datos de la estación	8 años
Resolución temporal	10 minutos


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

6.2


República Islámica del Irán (atlas de energía solar)



Atlas de energía solar de la República Islámica del Irán	
Recurso cartografiado	Radiación de onda corta incidente en superficie
Unidades de los datos	kWh/m²/día
Fuentes de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	114
Período que abarcan los datos de la estación	3 años
Resolución temporal	10 minutos


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

6.3 **Costa Rica (atlas de energía eólica)**


Mapas de la **velocidad del Viento a 10 m** en Costa Rica



Atlas de energía eólica de Costa Rica	
Recurso cartográfico	Velocidad del Viento a 10 m
Unidades de los datos	Grados decimales
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	41
Período que abarcan los datos de las estaciones	15 años
Resolución temporal	Horaria


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Velocidad del viento a 10 m




Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Velocidad del viento a 10 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Mapas de la **dirección del viento a 10 m** en Costa Rica



Atlas de energía eólica de Costa Rica	
Recurso cartográfico	Velocidad del Viento a 10 m
Unidades de los datos	Grados decimales
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	41
Período que abarcan los datos de las estaciones	15 años
Resolución temporal	Horaria


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Dirección del viento a 10 m




Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Dirección del viento a 10 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Mapas de la **dirección del viento a 100 m** en Costa Rica



Atlas de energía eólica de Costa Rica	
Recurso cartografiado	Velocidad del viento a 100 m
Unidades de los datos	m/s
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	41
Período que abarcan los datos de las estaciones	15 años
Resolución temporal	Horaria


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Velocidad del viento a 100 m




Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Velocidad del viento a 100 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Mapas de la **velocidad del viento a 100 m** en Costa Rica



Atlas de energía eólica de Costa Rica	
Recurso cartografiado	Dirección del Viento a 100 m
Unidades de los datos	Grados decimales
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	41
Período que abarcan los datos de las estaciones	15 años
Resolución temporal	Horaria


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Dirección del viento a 100 m




Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Dirección del viento a 100 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


6.4 Malawi (atlas hidroeléctrico)



Atlas de energía hidroeléctrica de Malawi	
Recurso cartografiado	Caudal
Unidades de los datos	m³/s
Fuente de datos primaria	GloFAS sometido a reducción de escala; la resolución espacial depende de los archivos de delimitación de cuencas hidrográficas proporcionados por HydroSHEDS
Número de estaciones	20
Período que abarcan los datos de las estaciones	27 años
Resolución temporal	Diaria


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Caudal medio diario



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


6.5 **Croatia (atlas de energía solar)**



Atlas de energía solar de Croacia	
Recurso cartografiado	Radiación de onda corta incidente en superficie
Unidades de los datos	kWh/m²/día
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	9
Período que abarcan los datos de las estaciones	5 años
Resolución temporal	1 h


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

6.6 Cuba (atlas de energía eólica y solar)


Mapas de la velocidad del Viento a 10 m en Cuba



Atlas de energía eólica de Cuba	
Recurso cartografiado	Velocidad del viento a 10 m
Unidades de los datos	m/s
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	65
Período que abarcan los datos de las estaciones	30
Resolución temporal	3 h

Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Velocidad del viento a 10 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Mapas de la **velocidad del Viento a 10 m en Cuba**



Atlas de energía eólica de Cuba	
Recurso cartografiado	Dirección del viento a 10 m
Unidades de los datos	Grados decimales
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	65
Período que abarcan los datos de las estaciones	30
Resolución temporal	3 h


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Dirección del viento a 10 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Mapas de la radiación solar en Cuba



Atlas de energía solar de Cuba	
Recurso cartografiado	Radiación de onda corta incidente en superficie
Unidades de los datos	kWh/m ² /día
Fuente de datos primaria	ERA5 sometido a reducción de escala a 90 m
Número de estaciones	–
Período que abarcan los datos de las estaciones	2 años
Resolución temporal	Mensual


Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Radiación (solar) de onda corta incidente en superficie




Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

6.7 **República Unida de Tanzania (atlas hidroeléctrico)**




Atlas de energía hidroeléctrica de la República Unida de Tanzania	
Recurso cartografiado	Caudal
Unidades de los datos	m ³ /s
Fuente de datos primaria	GloFAS sometido a reducción de escala; la resolución espacial depende de los archivos de delimitación de cuencas hidrográficas proporcionados por HydroSHEDS
Número de estaciones	–
Período que abarcan los datos de las estaciones	–
Resolución temporal	–

Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Caudal medio diario

Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Caudal medio diario



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Paso 7: Incorporación de las proyecciones climáticas

Nuestra metodología se aplica a los escenarios del CMIP6 (histórico, SSP3-7,0 y SSP5-8,5) del modelo CNRM-ESM2-1. Se estima la diferencia entre el escenario de las SSP y la serie temporal histórica. Esta diferencia representa el cambio proyectado para un período específico seleccionado por el usuario y posteriormente se añade a los datos de reanálisis ERA5 o GloFAS correspondientes. De esta forma los usuarios pueden analizar la posible evolución futura de la variable a lo largo de un período de tiempo seleccionado por el usuario. Para ver un ejemplo del código en Python correspondiente a este paso, consulte la sección A.7 del anexo (Paso 7:

Incorporación de datos de proyecciones climáticas). A continuación se presentan los productos que muestran los gráficos utilizados para visualizar las diferencias entre el escenario de las SSP y la serie temporal histórica para los nuevos países.

7.1 **Croacia**


Variación de la radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

7.2 Cuba


Mapas que muestran las diferencias de la velocidad del viento a 10 m en Cuba



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Mapas que muestran las diferencias de la dirección del viento a 10 m en Cuba


Variación de la dirección del viento a 10 m



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.


Mapas que muestran las diferencias de la radiación solar en Cuba

Variación de la radiación (solar) de onda corta incidente en superficie



Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

7.3

República Unida de Tanzania**Variación del caudal medio diario**

Fuente: Mapas de terceros. Los mapas proceden de la base de datos Natural Earth de 2025 y es posible que no se ajusten plenamente a las directrices cartográficas de las Naciones Unidas y la OMM.

Enseñanzas extraídas y perspectivas

Una de las principales enseñanzas extraídas del proyecto ha sido el papel central de la coproducción y la creación de capacidad para determinar las necesidades de los usuarios y garantizar la aplicación práctica de la metodología desarrollada. A lo largo de los talleres surgieron varias solicitudes técnicas recurrentes, principalmente relacionadas con la programación, como preguntas sobre los algoritmos y la estructura de los cuadernos de trabajo, así como dificultades relativas a la configuración de los equipos y la instalación de entornos. Algunos participantes también manifestaron su preferencia por las sesiones en directo para aumentar la interactividad o solicitaron talleres de seguimiento para resolver cuestiones concretas. Para dar respuesta a estas necesidades, una mejora útil podría consistir en facilitar los materiales de formación con antelación y organizar después una sesión práctica, una vez que los participantes hayan tenido tiempo de familiarizarse con las herramientas. Este enfoque permitiría subsanar mejor las carencias en competencias técnicas, puesto que muchas partes interesadas ya cuentan con experiencia en el manejo de datos climáticos y atlas nacionales. En este contexto, resulta más importante explicar el funcionamiento de la metodología desde una perspectiva computacional y técnica que centrarse en su finalidad meteorológica, la cual, por lo general, ya es bien comprendida por las partes interesadas. Otro desafío importante en la elaboración de atlas nacionales de recursos energéticos renovables es la disponibilidad y calidad de los datos de las estaciones. Muchas series temporales tienen una duración inferior a 10 años, lo que limita su utilidad para los análisis a largo plazo. A menudo, los datos se encuentran dispersos entre distintas instituciones, lo que dificulta su acceso y da lugar a formatos inconsistentes. Para salvar este problema, se ha creado un marco de integración unificado, respaldado por acuerdos formales de intercambio de datos que han logrado conectar conjuntos de datos que antes estaban aislados en varios países piloto.

Por último, el método de interpolación utilizado (ponderación de la distancia inversa) depende no solo del número de estaciones, sino también de su distribución espacial. Una red bien equilibrada, que cubra de manera uniforme todo el territorio nacional, es fundamental para obtener resultados fiables. Por consiguiente, las decisiones de eliminar estaciones debido a valores en falta o valores atípicos deben evaluarse cuidadosamente, dado que pueden reducir la representatividad espacial y comprometer la solidez de la interpolación.

APÉNDICE

Este anexo proporciona las secuencias de códigos Python necesarias para generar atlas nacionales de recursos energéticos renovables.

A.1 Paso 1: Recuperación de datos

La siguiente secuencia de comandos sirve para recuperar datos de la Copernicus Climate Data Store (CDS). Indica cómo se especifica una región geográfica (mediante un cuadro delimitador), el período temporal y las variables de interés.

```
import cdsapi

# Initialize the CDS API client c = cdsapi.Client()

# Define the data request parameters c.retrieve('reanalysis-era5-land', #This field defines
the data source
{
'variable': ['surface_solar_radiation_downwards', '10m_u_component_of_wind',
'10m_v_component_of_wind'], #Name of the variables
'area': [55, -10, 35, 30],      # North, West, South, East bounding box for Europe
'year': '2021',
'month': '01', 'day': [
'01', '02', '03'],
'time': [
'00:00', '01:00', '02:00', '03:00',
'04:00', '05:00', '06:00', '07:00',
'08:00', '09:00', '10:00', '11:00',
'12:00', '13:00', '14:00', '15:00',
'16:00', '17:00', '18:00', '19:00',
'20:00', '21:00', '22:00', '23:00'
],
'format': 'netcdf'
},
'namefile.nc')
```

A.2 Paso 2: Preprocesamiento de datos

La siguiente secuencia de comandos sirve para preprocesar tanto los datos de los modelos como los datos de las estaciones, incluidas funciones para la agregación temporal y el nuevo establecimiento de cuadrículas espaciales.

```
# Processing data and configurations

import xarray as xr
import geopandas as gpd
import numpy as np
import pandas as pd
from shapely.ops import cascaded_union
import os

from datetime import datetime
import glob

def preprocess_rean(xdf):
    """Adjust longitude bounds and round coordinates."""
    xdf['longitude'] = np.round(xdf.longitude, 3)
    xdf['latitude'] = np.round(xdf.latitude, 3)
```

```

if xdf.longitude.values.min() >= 0:
    xdf = roll_xdf(xdf)
return xdf

def roll_xdf(xdf):
    """Roll longitude from 0-360 to -180-180."""
    xdf = xdf.assign_coords(longitude=((xdf.longitude + 180) % 360) - 180))
    return xdf

def get_geometries(cut_on, shapefile=None):
    """Retrieve geometries for given region or bounding box coordinates."""
    if cut_on == 'europe':
        geometries = [-25, 32, 48.5, 75]
    elif cut_on == 'SADC':
        geometries = [2, -37, 60, 7]
    elif isinstance(cut_on, list):
        geometries = cut_on
    else:
        if not shapefile:
            geometries = get_boundaries(cut_on.capitalize(), continent=False)
        else:
            geometries = gpd.read_file(shapefile)
            geometries = geometries[geometries['NAME_EN'] == cut_on]['geometry']
    return geometries

def get_boundaries(name, continent=False):
    """Retrieve boundary geometries by name."""
    world_path = '../world_map/'
    world = gpd.read_file(world_path)

    if continent:
        world = world.query('REGION_UN == @name')
        boundary = gpd.GeoSeries(cascaded_union(world['geometry']))
    elif name in world['NAME_EN'].values:
        region_mask = world[world['NAME_EN'] == name]
        polygons = region_mask['geometry']
        boundary = gpd.GeoSeries(cascaded_union(polygons)) if (polygons.geom_type ==
'MultiPolygon').any() else gpd.GeoSeries(polygons)
    return boundary

def load_data(data_path):
    """Load river discharge dataset based on specified variable."""
    full_path = f"{data_path}/"
    files = sorted(glob.glob(full_path + 'era5land_surface_solar_radiation_*.nc'))
    print(files)
    try:
        xdf = xr.open_mfdataset(files, preprocess=preprocess_rean)
    except IOError as e:
        raise IOError(f"Files not found at {data_path}. Error: {e}")
    return xdf

def include_time_coord(ds):
    """Ensure time coordinate inclusion."""
    if 'time' not in ds.coords:
        ds = ds.assign_coords(time=('time', pd.date_range(datetime.now(), periods=ds.
dims['time'])))
    return ds

def normalize_naming(xdf):
    """Standardize variable names as required."""
    # Placeholder normalization, as naming conventions may vary

```

```

    return xdf.rename({'var_name_placeholder': 'variable_standard_name'})

def aggregate_daymean(xdf, var_name):
    """Compute daily mean for given variable."""
    xdf = xdf.rename({'valid_time':'time'})
    xdf_daymean = xdf[var_name].sel(time=xdf.time.dt.hour == 0) / 24
    return xdf_daymean

def cut_xdf(xdf, geometries):

    xdf = xdf.sortby('latitude')
    """Subset xdf using provided geometries."""
    # Assuming geometries are bounding box [lon_min, lat_min, lon_max, lat_max]
    # Assuming 'geometries' is a DataFrame with bounding box columns
    lon_min = geometries.bounds['minx'].values[0] # Extract minimum longitude
    lat_min = geometries.bounds['miny'].values[0] # Extract minimum latitude
    lon_max = geometries.bounds['maxx'].values[0] # Extract maximum longitude
    lat_max = geometries.bounds['maxy'].values[0] # Extract maximum latitude

    xdf_cut = xdf.sel(longitude=slice(lon_min, lon_max), latitude=slice(lat_min,
lat_max))
    return xdf_cut

##
data_path = 'data/cds_downloads/' ## FILL WITH THE PATH of ERASLAND data
output_path = 'data/downscaled_data/' ## FILL WITH THE PATH of desired OUTPUT PATH
country = 'croatia' ## FILL WITH THE COUNTRY NAME e.g. croatia, cuba

# Processing data and configurations
shapefile_path = '../world_map/ne_50m_admin_0_countries.shp'
geometries = get_geometries(f'{country.capitalize()}', shapefile_path)
def main(variable, data_sources, start_date, end_date, loading_area, aggregation_mode,
overwrite=False, data_path='', output_path=''):
    # Step 1: Define date range and load data
    xdf = load_data(data_path=data_path)

    # Step 2: Apply geographic masking if specified
    if loading_area:
        geometries = get_geometries(loading_area)
        xdf = cut_xdf(xdf, geometries)
        print(f>Data masked to the specified loading area: {loading_area}")

    # Step 3: Aggregate data by daily mean if required
    if aggregation_mode == 'daymean':
        xdf = aggregate_daymean(xdf, var_name=variable)
        print("Data aggregated by daily mean.")

    # Step 4: Save output if overwrite is enabled
    output_filename = f"{output_path}/{variable}_{start_date}_{end_date}_processed.nc"
    if overwrite or not os.path.exists(output_filename):
        os.makedirs(output_path, exist_ok=True)
        print(xdf)
        xdf = xdf.drop('number')
        xdf.to_netcdf(output_filename)
        print(f>Data written to {output_filename}")
    else:
        print(f"File already exists and overwrite is set to False: {output_filename}")

# Parameters (Example Usage)
main(
    variable='ssrd',

```

```

data _sources='era5land',
start _date='1992-01',
end _date='2020-12',
loading _area=country,
aggregation _mode='daymean',
data _path=data _path,
output _path=output _path,
overwrite=True
)

```

A.3 Paso 3: Reducción de escala

La siguiente secuencia de comandos sirve para reducir la escala de las variables de la CDS relacionadas con el atlas solar. Este ejemplo también es válido para la producción de energía eólica.

```

from sklearn.neural_network import MLPRegressor
from sklearn.preprocessing import StandardScaler
import numpy as np
import xarray as xr
import pandas as pd
import matplotlib.pyplot as plt
import rioxarray
import xarray as xr
import numpy as np
from cartopy.mpl.gridliner import LONGITUDE_FORMATTER, LATITUDE_FORMATTER

# Methods that are used below.

def round_coords(xdf, digits = None):
    """
    Rounds the coordinates of the xarray DataArray or Dataset to the specified number of
    decimal places.
    Needed to prevent issues due to excess decimal digits in coordinates, leading to
    grid mismatches.

    Parameters:
    xdf (xarray.DataArray or xarray.Dataset): The data containing 'latitude' and
    'longitude' to be rounded.
    digits (int, optional): The number of decimal places to round to. Defaults to 1 if
    not provided.

    Returns:
    xarray.DataArray or xarray.Dataset: The data with rounded coordinates.
    """
    if not digits:
        # Round latitude and longitude to 1 decimal place by default
        xdf['latitude'] = xdf.latitude.round(1).astype('float32')
        xdf['longitude'] = xdf.longitude.round(1).astype('float32')
    else:
        # Round latitude and longitude to the specified number of decimal places
        xdf['latitude'] = xdf.latitude.round(digits).astype('float32')
        xdf['longitude'] = xdf.longitude.round(digits).astype('float32')
    return xdf

def make_dataset_era5land(target_var, orography, aspect, monthly_avg = False):
    """
    Creates a dataset by merging a target variable, orography, and aspect data,
    optionally computing monthly averages.

    Parameters:

```

target_var (xarray.DataArray or xarray.Dataset): The target variable data.
 orography (xarray.DataArray or xarray.Dataset): Orography data.
 aspect (xarray.DataArray or xarray.Dataset): Aspect data.
 monthly_avg (bool, optional): Whether to compute monthly averages. Defaults to False.

Returns:

pandas.DataFrame: The merged dataset in a DataFrame format, with rounded coordinates.

```
"""
for xdf in [target_var, orography, aspect]:
    xdf = round_coords(xdf)

# Merge the datasets into one
xdf_merged = xr.merge([orography, aspect, target_var])

if monthly_avg:
    # Compute the monthly average if specified
    xdf_merged = xdf_merged.groupby(xdf_merged.time.dt.month).mean()

# Convert to DataFrame and drop NaN values
merged = xdf_merged.to_dataframe().dropna()
merged = merged.reset_index()

# Round coordinates for final output
merged['longitude'] = merged['longitude'].round(1)
merged['latitude'] = merged['latitude'].round(1)
return merged

def make_dataset_glo90(orography, aspect):
    """
    Creates a dataset by merging GLO-90 orography and aspect data, with coordinates
    rounded to 6 decimal places (as 90 m correspond to about 0.000808°).

    Parameters:
    orography (xarray.DataArray or xarray.Dataset): Orography data.
    aspect (xarray.DataArray or xarray.Dataset): Aspect data.

    Returns:
    pandas.DataFrame: The merged dataset in a DataFrame format, with NaN values for
    zeroes and reset index.
    """
    for xdf in [orography, aspect]:
        xdf = round_coords(xdf, digits = 6)

    # Merge the GLO-90 datasets
    merged_glo90 = xr.merge([orography, aspect])

    # Convert to DataFrame and drop NaN values
    merged_glo90 = merged_glo90.to_dataframe().dropna()
    merged_glo90 = merged_glo90.reset_index()

    return merged_glo90

def era5scaler(xdf, features, target):
    """
    Scales the features and target variables of the ERA5Land dataset using
    StandardScaler.

    Parameters:
    xdf (pandas.DataFrame): The dataset containing the features and target.
```

```

features (list of str): List of feature column names to scale.
target (str): The target column name to scale.

Returns:
tuple: The scaler for the target, scaled feature array, and scaled target array.
"""
featurescaler = StandardScaler()
# Scale the features
X_scaled = featurescaler.fit_transform(xdf[features])

targetscaler = StandardScaler()
# Scale the target
y_scaled = targetscaler.fit_transform(xdf[[target]]).ravel()

return targetscaler, X_scaled, y_scaled

def glo90scaler(xdf, features):
    """
    Scales the features of the GLO-90 dataset using StandardScaler.

    Parameters:
    xdf (pandas.DataFrame): The dataset containing the features.
    features (list of str): List of feature column names to scale.

    Returns:
    numpy.ndarray: The scaled feature array.
    """
    scaler_glo90 = StandardScaler()
    # Scale the features
    X_scaled = scaler_glo90.fit_transform(xdf[features])
    return X_scaled

def era5land_preparation(country):
    """ Load ERA5Land features """
    ssrd = xr.open_mfdataset(f'data/downscaled_data/ssrd_1992-01_2020-12_processed.nc')
    # ERA5Land-derived DEM and aspect datasets
    orography = xr.open_dataset(f'../DEMdata/{country}/era5land_orography_{country}.nc')
    aspect = xr.open_dataset(f'../DEMdata/{country}/era5land_aspect_{country}.nc')
    """ Make the datasets with longitude, latitude, month of the year, altitude, aspect,
    and surface downward solar radiation. """
    """ The datasets consider the average of the target wind variable for each month of
    the year across the input dataset. """

    ssrd_era5l_merged = make_dataset_era5land(ssrd, orography, aspect, monthly_avg = True)

    return ssrd_era5l_merged

ssrd_era5l_merged = era5land_preparation(country)

# Training the downscaling model on ERA5Land features
def training_ds(ssrd_era5l_merged, month):
    """ Select a target month (here is January); and then drop the month feature. """
    ssrd_era5l_merged = ssrd_era5l_merged.loc[ssrd_era5l_merged.month == month,:].drop('month', axis = 1)
    """ Scaling features and target """
    features = ssrd_era5l_merged.columns.drop(['ssrd','spatial_ref','number'])
    target = 'ssrd'

    """ This method returns the scaler (needed to turn the predictions of the model on

```

```

GLO-90 features into downscaled values),
    # and the scaled input feature set and target
    targetscaler_era5, era5l_X, era5l_y = era5scaler(ssrd_era5l_merged, features,
target)

    # Fit the downscaling model. The type of model is a neural network regressor
(multilayer perceptron)
    regr = MLPRegressor(random_state=1, max_iter = 1000).fit(era5l_X, era5l_y)

    return features, targetscaler_era5, era5l_X, era5l_y, regr

features, targetscaler_era5, era5l_X, era5l_y, regr = training_ds(ssrd_era5l_
merged, month)

def opening_glo90(country):
    ### Prepare the GLO-90 features
    orography_glo90 = xr.open_dataset(f'../DEMdata/{country}/glo90_orography_{country}.
nc')
    aspect_glo90 = xr.open_dataset(f'../DEMdata/{country}/glo90_aspect_{country}.nc')
    dataset_glo90 = make_dataset_glo90(orphography_glo90, aspect_glo90)
    dataset_glo90 = dataset_glo90.rename(columns = {'band_data':'aspect'})
    return dataset_glo90

dataset_glo90 = opening_glo90(country)

# Downscaling: use the model on GLO-90 features
def apply_downscaling(dataset_glo90, features, month, country):
    ### Scale GLO-90 features
    glo90_X = glo90scaler(dataset_glo90, features)

    ### Calculate the downscaled values
    downscaled_mlr_std = regr.predict(glo90_X) # These values are standardised, make
them go back to actual values
    downscaled_mlr = targetscaler_era5.inverse_transform(downscaled_mlr_std.
reshape(-1,1)) # Using the targetscaler
    dataset_glo90['ssrd_downscaled'] = downscaled_mlr
    output_ds = dataset_glo90.set_index(['latitude', 'longitude'])[['ssrd_downscaled']].
to_xarray()
    output_ds['ssrd_downscaled'] = output_ds['ssrd_downscaled'] * 24 / 3600000
    output_ds.to_netcdf(f'data/downscaled_data/ssrd_downscaled_{country}_m(month).
nc')
    return output_ds

output_ds = apply_downscaling(dataset_glo90, features, month, country)

```

La siguiente secuencia de comandos se utiliza para reducir la escala de las variables de la CDS relacionadas con el atlas de energía hidroeléctrica.

```

import rasterstats as rstats
import matplotlib.colors as colors
import rasterio as rio

# preprocess
import numpy as np
from scipy.interpolate import griddata
from datetime import timedelta, datetime, date
import dateutil.parser
import pandas as pd
from scipy.spatial import distance_matrix
import xarray as xr
import os

```

```

import numpy as np
import pandas as pd
import warnings
warnings.filterwarnings("ignore")
import geopandas as gpd
country = 'tanzania'## FILL WITH THE COUNTRY NAME
month = 1
data_path = 'data/downscaled_data/' ## FILL WITH THE PATH of GLOFAS data
output_path = 'data/downscaled_data/' ## FILL WITH THE PATH of desired OUTPUT PATH

# Processing data and configurations
# To create a fully WMO aligned map, WMO ShapeFiles and Styles must be used. Please
contact the Secretariat for details.
shapefile_path = '../world_map/ne_50m_admin_0_countries.shp'

geometries = gpd.read_file(shapefile_path).loc[:,['ADMIN','geometry']].set_index('ADMIN')
if country == 'tanzania':
    geometries_country = geometries.loc['United Republic of Tanzania']
else:
    geometries_country = geometries.loc[f'{country.capitalize()}']

# Load river discharge from GLOFAS. Filtering out values with discharge lower than 0.5
m/s to reduce noise.

in_path = 'data/downscaled_data/'

xdf_mal = xr.open_mfdataset(in_path + '*processed.nc')
xdf_alltime_avg = xdf_mal.mean('time')
xdf_alltime_avg = xdf_alltime_avg.where(xdf_alltime_avg.dis24>.5)
# Load river basins of levels 5 and 12 (highest resolution)
shp_basins_l5 = gpd.read_file('data/hydrobasins/hybas_lake_af_lev05_vlc.shp')
shp_basins_l12 = gpd.read_file('data/hydrobasins/hybas_lake_af_lev12_vlc.shp')
lakes_l5 = shp_basins_l5[shp_basins_l5.LAKE == 1].geometry # Saving lakes as mask
for plotting

shp_basins_l5 = shp_basins_l5[shp_basins_l5.LAKE == 0] # Exclude lakes from basins
shp_basins_l12 = shp_basins_l12[shp_basins_l12.LAKE == 0]

country_l5_basins = gpd.clip(shp_basins_l5, geometries_country.geometry) # Clip
basins over country.
country_lakes_l5 = gpd.clip(lakes_l5, geometries_country.geometry)
country_l12_basins = gpd.clip(shp_basins_l12, geometries_country.geometry)
country_l12_basins['L5basin'] = [int(str(i)[:5]) for i in country_l12_basins.PFAF_ID]

## Load rivers geometry

rivers = gpd.read_file('data/hydrobasins/HydroRIVERS_v10_af_shp/HydroRIVERS_v10_
af.shp')
sel_basin = gpd.GeoDataFrame(country_l5_basins.iloc[[2]])
country_rivers = gpd.clip(rivers, geometries_country.geometry)
sel_basin_rivers = gpd.clip(country_rivers, sel_basin)

# For using rasterstats's methods for calculating various statistics over geometries, we
need to know the geo transform of reference from one GLOFAS file
affine = rio.open('data/preprocessed_data/river_discharge_1992-01_2020-12_processed.
nc').transform
# Calculating the mean discharge over L5 basins from GLOFAS data
mean_basins_l5 = rststats.zonal_stats(country_l5_basins.geometry, xdf_alltime_avg.
dis24.values, affine = affine, stats = 'mean')
# Calculating the mean discharge over L12 basins from GLOFAS data
mean_basins_l12 = rststats.zonal_stats(country_l12_basins.geometry, xdf_alltime_

```

```
avg.dis24.values, affine = affine, stats = 'mean')
# Adding the values as columns of the datasets
country_l12_basins['mean_discharge'] = [stat['mean'] for stat in mean_basins_l12]
country_l15_basins['mean_discharge'] = [stat['mean'] for stat in mean_basins_l15]
```

A.4 Paso 4: Interpolación de datos

La siguiente secuencia de comandos aplica la función de ponderación de la distancia inversa. Es importante señalar que el preprocesamiento de los datos de las estaciones se adapta a cada país y no se trata en esta sección. El archivo de entrada con la ponderación de la distancia inversa se normaliza como un DataFrame de pandas, que contiene columnas correspondientes al tiempo, la latitud, la longitud, la variable y otra información adicional, como el nombre y el identificador de la estación.

```
# preprocess import numpy as np
from scipy.interpolate import griddata
from datetime import timedelta, datetime, date
import dateutil.parser
import pandas as pd
from scipy.spatial import distance_matrix
import xarray as xr
import os
import numpy as np
import pandas as pd
import warnings
warnings.filterwarnings("ignore")
def apply_idw(pdf, lat_new, lon_new):

    lat = pdf['latitude'].values
    lon = pdf['longitude'].values
    var = pdf['ssrd'].values

    # Locations of the IoT observations
    iot_grid = np.array(list(zip(lat, lon)))

    # Grid for IoT observation projection
    grid_new = np.array([x, y] for x in lat_new for y in lon_new)

    # Calculating IoT map with IDW
    iot_new = simple_idw(iot_grid, var, grid_new)

    # Reshaping results from array-like to matrix-like
    iot_reshape = iot_new.reshape(len(lat_new), len(lon_new))

    return iot_reshape

def simple_idw(pos, z, posi):

    # Distance matrix
    dist = distance_matrix(pos, posi)**3

    # Weight matrix
    weights = 1.0 / dist

    # Change diagonal values to 1
    np.fill_diagonal(weights, 1)

    # Normalizing each column of the weight matrix
    weights = weights/np.nansum(weights, axis=0)

    # Calculating the results of the IDW method
```

```

zi = np.dot(weights.T, z)

return zi

var_df_month_reshaped = apply_idw(var_df_month, lat_idw_new, lon_idw_new)

```

A.5 Paso 5: Generación de atlas

La siguiente secuencia de comandos sirve para generar el atlas nacional de recursos energéticos renovables. Los conjuntos de datos del paso 3 (Reducción de escala) y del paso 4 (Interpolación de datos) se combinan aplicando la etapa final de la metodología. También incluye el procedimiento para guardar el producto resultante.

```

def apply_dist(pdf, lat_new, lon_new):

    lat = pdf['latitude'].drop_duplicates().values
    lon = pdf['longitude'].drop_duplicates().values

    # Locations of the IoT observations
    iot_grid = np.array(list(zip(lat, lon)))

    # Grid for IoT observation projection
    grid_new = np.array([x, y] for x in lat_new for y in lon_new)

    # Calculating IoT map
    iot_new = distances(iot_grid, grid_new)

    # Reshaping results from array-like to matrix-like
    iot_reshape = []
    for i in np.arange(0, len(iot_new)):
        iot_reshape.append(iot_new[i].reshape(len(lat_new), len(lon_new)))

    return iot_reshape

def distances(pos, posi):

    # Distance matrix
    dist = distance_matrix(pos, posi)**3          #this is what we need

    return dist

def min_distances(idw_ds, data_path, country):
    lat_fin = idw_ds.latitude.to_numpy()
    lon_fin = idw_ds.longitude.to_numpy()
    stats_data = pd.read_csv(stations_path)
    dist_matrices = apply_dist(stats_data, lat_fin, lon_fin)

    for i in np.arange(1, len(dist_matrices)):
        if i == 1:
            min_init = np.minimum(dist_matrices[i], dist_matrices[i-1])
        else:
            min_dist = np.minimum(min_init, dist_matrices[i])

    min_dist_xr = xr.DataArray(min_dist, coords=[("latitude", lat_fin), ("longitude", lon_fin)])

    # NORMALIZATION
    min_dist_xr_norm = (min_dist_xr - min_dist_xr.min()) / (min_dist_xr.max() - min_dist_xr.min())
    return min_dist_xr_norm

```

```

min_dist_xr_norm = min_distances(idw_ds,data_path,country)

def uncertainties(min_dist_xr_norm):
    #uncertainties of the era5 dataset
    sigma_2_era5_norm= (0.2)**2

    #uncertainties of the idw dataset
    sigma_2_idw_norm = (0.4 + min_dist_xr_norm)**2

    return sigma_2_era5_norm, sigma_2_idw_norm
sigma_2_era5_norm, sigma_2_idw_norm = uncertainties(min_dist_xr_norm)

def apply_scaling(era5_ds, sigma_2_era5_norm, idw_ds, sigma_2_idw_norm,n_
month,country):
    var_scaled = ((era5_ds.ssrds_downscaled / sigma_2_era5_norm) +
                  (idw_ds.ssrds_reshaped / sigma_2_idw_norm)) / ((1/sigma_2_era5_
norm) + (1/sigma_2_idw_norm))

    var_scaled_xr = var_scaled.to_dataset(dim=None, name='ssrd_integrated')
    var_scaled_xr.to_netcdf(output_path+f'/ssrd_integrated_{country}_m{n_month}.
nc')

    geotiff_file = creating_geotiff(var_scaled_xr,country,n_month)
    return var_scaled_xr

def creating_geotiff(file_netcdf,country,n_month):
    bT = file_netcdf['ssrd_integrated']
    bT = bT.rio.set_spatial_dims(x_dim='longitude', y_dim='latitude')
    bT.rio.crs
    # Define the CRS projection
    bT = bT.rio.write_crs("epsg:4326", inplace=True)
    bT.rio.to_raster(output_path+f'/ssrd_integrated_{country}_m{n_month}.tif')
    return bT

ssrd_integrated_xr = apply_scaling(era5_ds, sigma_2_era5_norm, idw_ds,
sigma_2_idw_norm,month,country)

```

A.6 Paso 6: Visualización

La siguiente secuencia de comandos sirve para generar y guardar las imágenes relacionadas con el atlas nacional de recursos energéticos renovables.

```

import matplotlib.pyplot as plt
import cartopy.crs as ccrs
import cartopy.feature as cfeature
import cartopy.io.img_tiles as cimgt
import matplotlib.colors as mcolors
import matplotlib.cm as cm

orog = xr.open_dataset(f'../DEMdata/{country}/glo90_orography_{country}.nc')
mask = orog['z'] > 2000

import cartopy.io.img_tiles as cimgt

class StadiaStamen(cimgt.Stamen):
    def _image_url(self, tile):
        x,y,z = tile
        url = f"https://tiles.stadiamaps.com/tiles/stamen_terrain_background/{z}/{x}/{y}.png?api_key=16f26ea8-2565-4da3-972a-49888d65b1e8"
        return url

```

```

class StadiaMap(cimgt.GoogleTiles):
    def __init__(self, style='alidade_smooth'):
        self._style = style
        super().__init__()

    def _image_url(self, tile):
        x, y, z = tile
        url = f"https://tiles.stadiamaps.com/tiles/{self._style}/{z}/{x}/{y}.png?api_key=16f26ea8-2565-4da3-972a-49888d65b1e8"
        return url

def draw_map(xdf, vmin, vmax, legend=False, label=None, title=None, supitle=None,
orient='vertical'):

    fig, ax = plot.subplots(ncols=1, figsize=(10, 7), subplot_kw={'projection': ccrs.
PlateCarree()})

    # Create a Stamen terrain background map
    #stamen_terrain = StadiaStamen("terrain-background")
    stadia_terrain = StadiaMap("stamen_terrain_background")

    #ax.add_image(stadia_terrain, 6)

    ax.add_feature(cfeature.LAKES, edgecolor='black', facecolor='light blue')
    ax.add_feature(cfeature.OCEAN, edgecolor='light blue')
    ax.add_feature(cfeature.RIVERS, edgecolor='light blue')
    ax.add_feature(cfeature.COASTLINE, edgecolor='black', linewidth=1.2)
    ax.add_feature(cfeature.BORDERS, edgecolor='black', linewidth=1.2)

    xdf.rio.set_spatial_dims(x_dim="longitude", y_dim="latitude", inplace=True)
    xdf.rio.write_crs("epsg:4326", inplace=True)

    #xdf = xdf.rio.clip geometries)

    cbar_kwargs = {
        'orientation': 'vertical',
        'shrink': 0.25,
        'aspect': 50,
        'pad': 0.2,
        'label': label,
        'labelsize': 11,
    }

    if legend else None

    #xdf.plot(cmap='reds', ax=ax, vmin=vmin, vmax=vmax)
    im = xdf.plot.pcolormesh(ax = ax, transform=ccrs.PlateCarree(),
                            #norm=LogNorm(),
                            vmin=vmin, vmax=vmax,
                            cmap='Fire',
                            add_colorbar=legend,
                            add_labels=False,
                            cbar_kwargs=cbar_kwargs
                            )

    if orient == 'horizontal':
        cbar = im.colorbar
        cbar.ax.tick_params(axis='y', rotation=90)

    # Add longitude-latitude grid
    gl = ax.gridlines(draw_labels=True, linewidth=0.5, color='gray', alpha=0.5,
linestyle='--')

```

```

gl.xlabels_top = False
gl.ylabel_s_right = False
gl.xformatter = LONGITUDE_FORMATTER
gl.yformatter = LATITUDE_FORMATTER

lat_min = np.min(xdf.latitude.values) -1
lat_max = np.max(xdf.latitude.values) +1
lon_min = np.min(xdf.longitude.values)-1
lon_max = np.max(xdf.longitude.values) +1

ax.set_extent([lon_min, lon_max, lat_min, lat_max], crs=ccrs.PlateCarree())
ax.set_title(title, fontsize=14)
fig.suptitle(suptitle, fontsize=17)
return fig

fig = draw_map(xdf['ssrd_integrated'].where(~mask, drop=False), 0, 8, True, 'Surface
short-wave (solar) radiation downwards(kWh/m²/day)',
              months_names[month-1], 'Solar Radiation')
#fig.save(f'figures/INTEGRATED_rd_{country}_overall_solar_era5land_month{month}.png')

```

A.7 Paso 7: Incorporación de las proyecciones climáticas

La siguiente secuencia de comandos sirve para el preprocesamiento de los datos de proyecciones climáticas futuras.

```

# Processing data and configurations

import xarray as xr
import geopandas as gpd
import numpy as np
import pandas as pd
from shapely.ops import cascaded_union
import os

def preprocess_rean(xdf):
    xdf = xdf.rename({'lon':'longitude','lat':'latitude'})
    """Adjust longitude bounds and round coordinates."""
    xdf['longitude'] = np.round(xdf.longitude, 3)
    xdf['latitude'] = np.round(xdf.latitude, 3)
    xdf = xdf.drop('time_bounds')

    if xdf.longitude.values.max() >= 300:
        xdf = roll_xdf(xdf)

    if exp == 'historical':
        xdf = xdf.sel(time=slice('1985','2014'))
    else:
        xdf = xdf.sel(time=slice('2015','2100'))

    return xdf

def roll_xdf(xdf):
    """Roll longitude from 0-360 to -180-180."""
    xdf = xdf.assign_coords(longitude=((xdf.longitude + 180) % 360) - 180))
    xdf = xdf.sortby(xdf.longitude)
    return xdf

def get_geometries(cut_on, shapefile=None):

```

```

"""Retrieve geometries for given region or bounding box coordinates."""
if cut_on == 'europe':
    geometries = [-25, 32, 48.5, 75]
elif cut_on == 'SADC':
    geometries = [2, -37, 60, 7]
elif isinstance(cut_on, list):
    geometries = cut_on
else:
    if not shapefile:
        geometries = get_boundaries(cut_on.capitalize(), continent=False)
    else:
        geometries = gpd.read_file(shapefile)
        geometries = geometries[geometries['NAME_EN'] == cut_on]['geometry']
return geometries

def get_boundaries(name, continent=False):
    """Retrieve boundary geometries by name."""
    world_path = '../world_map/'
    world = gpd.read_file(world_path)

    if continent:
        world = world.query('REGION_UN == @name')
        boundary = gpd.GeoSeries(cascaded_union(world['geometry']))
    elif name in world['NAME_EN'].values:
        region_mask = world[world['NAME_EN'] == name]
        polygons = region_mask['geometry']
        boundary = gpd.GeoSeries(cascaded_union(polygons)) if (polygons.geom_type ==
'MultiPolygon').any() else gpd.GeoSeries(polygons)
    return boundary
from datetime import datetime
import glob

def load_data(data_path):
    """Load river discharge dataset based on specified variable."""
    #full_path = f"{data_path}/"
    #files = sorted(glob.glob(full_path + 'era5land_surface_solar_radiation_*.nc'))
    #?
    #print(files)
    try:
        xdf = xr.open_mfdataset(data_path+'/*.nc', preprocess=preprocess_rean)
    except IOError as e:
        raise IOError(f"Files not found at {data_path}. Error: {e}")
    return xdf

def include_time_coord(ds):
    """Ensure time coordinate inclusion."""
    if 'time' not in ds.coords:
        ds = ds.assign_coords(time=('time', pd.date_range(datetime.now(), periods=ds.
dims['time'])))
    return ds

def normalize_naming(xdf):
    """Standardize variable names as required."""
    # Placeholder normalization, as naming conventions may vary
    return xdf.rename({'var_name_placeholder': 'variable_standard_name'})

def aggregate_daymean(xdf, var_name):
    """Compute daily mean for given variable."""
    #xdf = xdf.rename({'valid_time': 'time'})
    xdf_daymean = xdf[var_name].sel(time=xdf.time.dt.hour == 0) / 24

```

```

return xdf_daymean

def cut_xdf(xdf, geometries):

    xdf = xdf.sortby('latitude')
    """Subset xdf using provided geometries."""
    # Assuming geometries are bounding box [lon_min, lat_min, lon_max, lat_max]
    # Assuming 'geometries' is a DataFrame with bounding box columns
    lon_min = geometries.bounds['minx'].values[0] # Extract minimum longitude
    lat_min = geometries.bounds['miny'].values[0] # Extract minimum latitude
    lon_max = geometries.bounds['maxx'].values[0] # Extract maximum longitude
    lat_max = geometries.bounds['maxy'].values[0] # Extract maximum latitude

    xdf_cut = xdf.sel(longitude=slice(lon_min, lon_max), latitude=slice(lat_min,
lat_max))
    return xdf_cut
def main(variable, model, experiment, start_date, end_date, loading_area,
aggregation_mode, overwrite, data_path, output_path):
    # Step 1: Define date range and load data
    xdf = load_data(data_path=data_path)

    # Step 2: Apply geographic masking if specified
    if loading_area:
        geometries = get_geometries(loading_area)
        xdf = cut_xdf(xdf, geometries)
        print(f"Data masked to the specified loading area: {loading_area}")

    # Step 3: Aggregate data by daily mean if required
    if aggregation_mode == 'daymean':
        xdf = aggregate_daymean(xdf, var_name=variable)
        print("Data aggregated by daily mean.")

    # Step 4: Save output if overwrite is enabled
    output_filename = f"{output_path}/{variable}_{start_date}_{end_date}_processed.
nc"
    if overwrite or not os.path.exists(output_filename):
        os.makedirs(output_path, exist_ok=True)
        print(xdf)
        xdf.to_netcdf(output_filename)
        print(f"Data written to {output_filename}")
    else:
        print(f"File already exists and overwrite is set to False: {output_filename}")
##

data_path = 'data/cds_downloads/' ## FILL WITH THE PATH of ERA5LAND data
output_path = 'data/downscaled_data/' ## FILL WITH THE PATH of desired OUTPUT PATH
variable = 'rsds'
model = 'CNRM-ESM2-1'
exps = ['historical', 'ssp370', 'ssp585']
country = 'croatia' ## FILL WITH THE COUNTRY NAME e.g. croatia, cuba

# Processing data and configurations
shapefile_path = '../world_map/ne_50m_admin_0_countries.shp'

geometries = get_geometries(f'{country.capitalize()}', shapefile_path)

for exp in exps:
    if exp == 'historical':
        start = '1985-01'
        end = '2014-12'

```

```

else:
    start = '2015-01'
    end = '2100-12'

scen_path = data_path+f'/{exp}/{model}/'
out_path = output_path+f'/{exp}/{model}/'

# Parameters (Example Usage)
main(
    variable      = var,
    model         = model,
    experiment     = exp,
    start_date    = start,
    end_date      = end,
    loading_area  = country.capitalize(),
    aggregation_mode = None,
    data_path     = scen_path,
    output_path   = out_path,
    overwrite     = True)

```

La siguiente secuencia de comandos sirve para reducir la escala de los datos de proyecciones climáticas futuras sobre energía solar y eólica.

```

## REQUIRES conda_solar_wind enviroment from conda_solar_wind.yml

from sklearn.neural_network import MLPRegressor
from sklearn.preprocessing import StandardScaler
import numpy as np
import xarray as xr
import pandas as pd
import matplotlib.pyplot as plt
import rioxarray
import xarray as xr
import numpy as np
from cartopy.mpl.gridliner import LONGITUDE_FORMATTER, LATITUDE_FORMATTER

import warnings
warnings.filterwarnings("ignore")
# Methods that are used below.

def round_coords(xdf, digits = None):
    """
    Rounds the coordinates of the xarray DataArray or Dataset to the specified number of
    decimal places.
    Needed to prevent issues due to excess decimal digits in coordinates, leading to
    grid mismatches.

    Parameters:
    xdf (xarray.DataArray or xarray.Dataset): The data containing 'latitude' and
    'longitude' to be rounded.
    digits (int, optional): The number of decimal places to round to. Defaults to 1 if
    not provided.

    Returns:
    xarray.DataArray or xarray.Dataset: The data with rounded coordinates.
    """
    if not digits:
        # Round latitude and longitude to 1 decimal place by default
        xdf['latitude'] = xdf.latitude.round(1).astype('float32')
        xdf['longitude'] = xdf.longitude.round(1).astype('float32')

```

```

else:
    # Round latitude and longitude to the specified number of decimal places
    xdf['latitude'] = xdf.latitude.round(digits).astype('float32')
    xdf['longitude'] = xdf.longitude.round(digits).astype('float32')
    return xdf

def make__dataset__era5land(target__var, orography, aspect, monthly__avg = False):
    """
    Creates a dataset by merging a target variable, orography, and aspect data,
    optionally computing monthly averages.

    Parameters:
    target__var (xarray.DataArray or xarray.Dataset): The target variable data.
    orography (xarray.DataArray or xarray.Dataset): Orography data.
    aspect (xarray.DataArray or xarray.Dataset): Aspect data.
    monthly__avg (bool, optional): Whether to compute monthly averages. Defaults to
    False.

    Returns:
    pandas.DataFrame: The merged dataset in a DataFrame format, with rounded
    coordinates.
    """
    target__var = target__var.interp__like(orography, method="nearest")

    for xdf in [target__var, orography, aspect]:
        xdf = round__coords(xdf)

    # Merge the datasets into one
    xdf__merged = xr.merge([orography, aspect, target__var])

    if monthly__avg:
        # Compute the monthly average if specified
        xdf__merged = xdf__merged.groupby(xdf__merged.time.dt.month).mean()

    # Convert to DataFrame and drop NaN values
    merged = xdf__merged.to__dataframe().dropna()
    merged = merged.reset__index()

    # Round coordinates for final output
    merged['longitude'] = merged['longitude'].round(1)
    merged['latitude'] = merged['latitude'].round(1)
    return merged

def make__dataset__glo90(orography, aspect):
    """
    Creates a dataset by merging GLO-90 orography and aspect data, with coordinates
    rounded to 6 decimal places (as 90 m correspond to about 0.000808°).

    Parameters:
    orography (xarray.DataArray or xarray.Dataset): Orography data.
    aspect (xarray.DataArray or xarray.Dataset): Aspect data.

    Returns:
    pandas.DataFrame: The merged dataset in a DataFrame format, with NaN values for
    zeroes and reset index.
    """
    for xdf in [orography, aspect]:
        xdf = round__coords(xdf, digits = 6)

    # Merge the GLO-90 datasets
    merged__glo90 = xr.merge([orography, aspect])

```

```

# Convert to DataFrame and drop NaN values
merged_glo90 = merged_glo90.to_dataframe().dropna()
merged_glo90 = merged_glo90.reset_index()

return merged_glo90

def era5scaler(xdf, features, target):
    """
    Scales the features and target variables of the ERA5Land dataset using
    StandardScaler.

    Parameters:
    xdf (pandas.DataFrame): The dataset containing the features and target.
    features (list of str): List of feature column names to scale.
    target (str): The target column name to scale.

    Returns:
    tuple: The scaler for the target, scaled feature array, and scaled target array.
    """
    featurescaler = StandardScaler()
    # Scale the features
    X_scaled = featurescaler.fit_transform(xdf[features])

    targetscaler = StandardScaler()
    # Scale the target
    y_scaled = targetscaler.fit_transform(xdf[[target]]).ravel()

    return targetscaler, X_scaled, y_scaled

def glo90scaler(xdf, features):
    """
    Scales the features of the GLO-90 dataset using StandardScaler.

    Parameters:
    xdf (pandas.DataFrame): The dataset containing the features.
    features (list of str): List of feature column names to scale.

    Returns:
    numpy.ndarray: The scaled feature array.
    """
    scaler_glo90 = StandardScaler()
    # Scale the features
    X_scaled = scaler_glo90.fit_transform(xdf[features])
    return X_scaled

def apply_ds(var, name, month):
    era5l_merged = make_dataset_era5land(var, orography, aspect, monthly_avg = True)
    era5l_merged = era5l_merged.loc[era5l_merged.month == month,:].drop('month', axis =
1)

    features = era5l_merged.columns.drop([name, 'spatial_ref'])
    target = name
    targetscaler_era5, era5l_X, era5l_y = era5scaler(era5l_merged, features, target)
    regr = MLPRegressor(random_state=1, max_iter = 1000).fit(era5l_X, era5l_y)
    glo90_X = glo90scaler(dataset_glo90, features)
    downscaled_mlr_std = regr.predict(glo90_X) # These values are standardised, make
them go back to actual values
    downscaled_mlr = targetscaler_era5.inverse_transform(downscaled_mlr_std.
reshape(-1,1)) # Using the targetscaler
    return downscaled_ml

country = 'croatia'
orography = xr.open_dataset(f'../DEMdata/{country}/era5land_orography_{country}.nc')

```

```

aspect = xr.open_dataset(f'../DEMdata/{country}/era5land_aspect_{country}.nc')
orography_glo90 = xr.open_dataset(f'../DEMdata/{country}/glo90_orography_{country}.nc')
aspect_glo90 = xr.open_dataset(f'../DEMdata/{country}/glo90_aspect_{country}.nc')
dataset_glo90 = make_dataset_glo90(orography_glo90, aspect_glo90)
dataset_glo90 = dataset_glo90.rename(columns = {'band_data':'aspect'})
exp = 'ssp585'
model = 'CNRM-ESM2-1'
var = 'rsds'

if exp == 'historical':
    start_data = 1985
    end_data = 2014
else:
    start_data = 2015
    end_data = 2100
rsds = xr.open_mfdataset(f'data/downscaled_data/{exp}/{model}/rsds_{start_data}_{end_data}_processed.nc')
start_period = '' #SELECT THE STARTING YEAR OF THE DECADE I WANT TO ANALYZE
end_period = '' #SELECT THE ENDING YEAR OF THE DECADE I WANT TO ANALYZE
month = 1
rsds = rsds.sel(time=slice(f'{start_period}',f'{end_period}'))
downscaled_mlr = apply_ds(rsds, var, month)
dataset_glo90['ssrd_downscaled'] = downscaled_mlr
output = dataset_glo90.set_index(['latitude', 'longitude'])['ssrd_downscaled'].to_xarray()
output['ssrd_downscaled'] = output['ssrd_downscaled'] * 24 / 1000 # from W/m2 to kWh/m2/day

output.to_netcdf(f'data/downscaled_data/{exp}/{model}/ssrd_downscaled_{country}_m{month}_{start_period}_{end_period}.nc')

```

A continuación se muestra un ejemplo de secuencia de comandos para calcular la diferencia en los atlas de energía solar y eólica.

```

import xarray as xr
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

import warnings
warnings.filterwarnings("ignore")
def opening_downscaling_cmip(downscaled_path, model, exp, country, month, start, end):
    if exp == 'historical':
        start_year = 1985
        end_year = 2014
    else:
        start_year = start
        end_year = end
    ds = xr.open_dataset(downscaled_path+f'{exp}/{model}/ssrd_downscaled_{country}_m{month}_{start}_{end}.nc')
    return ds
def calculate_future_delta(downscaled_path, country, month, hist_ds, ssp_ds, start, end, output_path):
    pres_ds = xr.open_dataset(downscaled_path+f'/ssrd_downscaled_{country}_m{month}.nc')

    delta = (ssp_ds.ssrd_downscaled - hist_ds.ssrd_downscaled).to_dataset(name='delta')
    future_ds = (pres_ds.ssrd_downscaled + delta.delta).to_dataset(name='ssrd_

```

```

downscaled')
    future_ds.assign(delta=delta["delta"])
    future_ds.to_netcdf(output_path+f'/{exp}/{model}/ssrd_delta_{country}_m{month}_{start}_{end}.nc')
    return future_ds
month = 1
country = 'cuba'
model = 'CNRM-ESM2-1'
start = 2030
end = 2049
downscaled_path = f'data/downscaled_data/'
output_path = 'data/atlas_data/'

hist_monthly_ds = opening_downscaling_cmip(downscaled_path, model, 'historical',
country, month, start, end)
s585_monthly_ds = opening_downscaling_cmip(downscaled_path, model, 'ssp585',
country, month, start, end)
s370_monthly_ds = opening_downscaling_cmip(downscaled_path, model, 'ssp370',
country, month, start, end)

ft_370_month = calculate_future_delta(downscaled_path, country, month, hist_monthly_ds, s370_monthly_ds,
start, end, output_path)
ft_585_month = calculate_future_delta(downscaled_path, country, month, hist_monthly_ds, s585_monthly_ds,
start, end, output_path)

```

A continuación se muestra un ejemplo de secuencia de comandos para calcular la diferencia en los atlas de energía hidroeléctrica.

```

import xarray as xr
import geopandas as gpd
import numpy as np
import glob
import rasterio as rio
import os

def get_geometries(region_name, shapefile=None):
    """Retrieve geometries for a specified region name or bounding box coordinates."""
    if shapefile:
        world = gpd.read_file(shapefile)
        geometries = world[world['NAME_EN'] == region_name]['geometry']
    else:
        # Example coordinates for bounding box if shapefile is not available
        geometries = [-180, -90, 180, 90]
    return geometries

def cut_xdf(xdf, geometries):
    """Subset xdf using provided geometries."""
    xdf = xdf.rio.write_crs("epsg:4326")
    xdf = xdf.rio.clip(geometries)

    return xdf

country = 'tanzania'
shapefile_path = '../world_map/ne_50m_admin_0_countries.shp'
geometries = get_geometries(country.capitalize(), shapefile=shapefile_path)
cmip_path = 'data/cds_downloads/' ## FILL WITH THE PATH of CMIP data
data_path = 'data/downscaled_data/' ## FILL WITH THE PATH of GLOFAS data
rivers_path = '../HydroRIVERS_v10_af_shp/HydroRIVERS_v10_af.shp'

```

```

model = 'CNRM-ESM2-1'

def cmip_preprocess(cmip_path, exp, model):
    in_path = cmip_path+f'/{exp}/{model}/'
    cmip_data = xr.open_mfdataset(in_path+'*.nc').
rename({'lat':'latitude','lon':'longitude'}).drop('time_bounds')
    cmip_data.rio.set_spatial_dims(x_dim='longitude', y_dim='latitude')
    cmip_data.rio.write_crs("epsg:4326", inplace=True)
    cmip_data_country = cut_xdf(cmip_data, geometries)
    return cmip_data_country

cmip_historical = cmip_preprocess(cmip_path, 'historical', model)
cmip_ssp370 = cmip_preprocess(cmip_path, 'ssp370', model)
cmip_ssp585 = cmip_preprocess(cmip_path, 'ssp585', model)

reanalysis_data = xr.open_mfdataset(data_path+'*.nc')

def upscaling(cmip_ds, glofas_ds):
    # Calculating "coarsen" factors along latitudine and longitude
    factor_lat = int(glofas_ds.dims['latitude'] / cmip_ds.dims['latitude'])
    factor_lon = int(glofas_ds.dims['longitude'] / cmip_ds.dims['longitude'])
    # Use coarsen to reduce the glofas dataset resolution

    # Extract the maximum discharge value of the cells
    ds_highres_coarsened = glofas_ds.coarsen(latitude=factor_lat, longitude=factor_
lon, boundary='trim').max()
    ds_highres_on_lowres = ds_highres_coarsened.interp_like(cmip_ds.mean('time'))

    return ds_highres_on_lowres

reanalysis_data_lr = upscaling(cmip_historical, reanalysis_data)

start = ''
end = ''
month = 1
annual_mean = True

def delta_making(cmip_historical, cmip_ssp, reanalysis_ds, start, end, month,
annual_mean):
    cmip_historical = cmip_historical.sel(time=slice('1985','2014'))
    cmip_ssp_decade = cmip_ssp.sel(time=slice(f'{start}',f'{end}'))

    if annual_mean == True:
        delta = (cmip_ssp_decade.groupby('time.month').mean().mean('month').rivo - cmip_
historical.groupby('time.month').mean().mean('month').rivo ).to_dataset(name='delta')
        reanalysis_ds_groupby = reanalysis_ds.groupby('time.month').mean().
mean('month')
    else:
        delta = (cmip_ssp_decade.groupby('time.month').mean().sel(month=month).
rivo - cmip_historical.groupby('time.month').mean().sel(month=month).rivo).to_
dataset(name='delta')
        reanalysis_ds_groupby = reanalysis_ds.groupby('time.month').mean().
sel(month=month)

    reanalysis_ds_future = (reanalysis_ds_groupby.dis24 + delta.delta).to_
dataset(name='dis24')
    reanalysis_ds_future['delta'] = delta['delta']

    return reanalysis_ds_future

```

```
# Calculate the delta on the upscaled low-resolution grid
reanalysis_ds_ssp370 = delta_making(cmip_historical, cmip_ssp370, reanalysis_
data_lr,
                                start, end, month, annual_mean)

reanalysis_ds_ssp585 = delta_making(cmip_historical, cmip_ssp585, reanalysis_
data_lr,
                                start, end, month, annual_mean)

# Return to the high-resolution grid of the GLOFAS data
reanalysis_ds_ssp370 = reanalysis_ds_ssp370.interp_like(reanalysis_data.
mean('time'),method='slinear')
reanalysis_ds_ssp585 = reanalysis_ds_ssp585.interp_like(reanalysis_data.
mean('time'),method='slinear')

def rivers_clipping(shapefile_path, rivers_path, country, reanalysis_ds):
    geometries = gpd.read_file(shapefile_path).loc[:,['ADMIN','geometry']].set_
index('ADMIN')
    if country == 'tanzania':
        country_geometry = geometries.loc['United Republic of Tanzania']
    else:
        country_geometry = geometries.loc[f'{country.capitalize()}']

    rivers = gpd.read_file(rivers_path)
    country_rivers = gpd.clip(rivers, country_geometry.geometry)
    rivers_only = country_rivers[country_rivers.ORD_FLOW<7]

    reanalysis_ds.rio.set_spatial_dims(x_dim='longitude', y_dim='latitude')
    reanalysis_ds.rio.write_crs("epsg:4326", inplace=True)

    reanalysis_ds_clipped = reanalysis_ds.rio.clip(rivers_only.geometry.values,
rivers_only.crs)
    return reanalysis_ds_clipped, country_rivers

reanalysis_ds_ssp370_clipped, country_rivers = rivers_clipping(shapefile_path,
rivers_path, country, reanalysis_ds_ssp370)
reanalysis_ds_ssp585_clipped, country_rivers = rivers_clipping(shapefile_path,
rivers_path, country, reanalysis_ds_ssp585)
```

Para más información, diríjase a:

Organización Meteorológica Mundial

7 bis, avenue de la Paix – Case postale 2300 – CH 1211 Genève 2 – Suiza

Oficina de Comunicación Estratégica

Tel.: +41 (0) 22 730 8314

Correo electrónico: cpa@wmo.int

wmo.int