Facultad de Derecho, Universidad Pontificia Comillas - ICADE

Construcción del Indicador de Circularidad de Residuos Urbanos en Europa (ICRU)

Autor: Gabriel Garbisu Martín

Director: David Roch Dupré

MADRID | Junio 2026

Índice

I. MEMORIA

1. Introducción 7

1.1 Contexto general: transición hacia la economía circular en la Unión Europea . 7

1.2 Marco normativo europeo y plano nacional 8

1.3 Estado del arte: indicadores y metodologías existentes..... 9

1.4 Motivación y aportación del Indicador de Circularidad de Residuos Urbanos (ICRU) 14

1.5 Objetivos del trabajo..... 15

1.6 Metodología general de construcción del índice 15

2. Diseño conceptual del ICRU 16

2.1 Fundamentos metodológicos del indicador compuesto..... 16

2.2 Definición de las dimensiones del ICRU 17

2.3 Selección y definición de las variables..... 19

3. Construcción del ICRU 21

3.1 Construcción de la base de datos..... 22

3.2 Tratamiento de los valores ausentes 23

3.3 Normalización y orientación de las variables..... 26

3.4 Análisis multivariante..... 27

3.5 Ponderación 29

3.6 Agregación..... 31

4. Resultados, robustez y validación 32

4.1 Resultados..... 32

4.2 Análisis de robustez..... 36

4.3 Validación externa 39

5. Conclusiones..... 39

6. Bibliografía..... 42

7. Anexos..... 45

7.1 Código fuente 45

7.2 Figuras 73

7.3 Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado..... 90

Índice de figuras

Figura 1. Estructura conceptual del ICRU: dimensiones e indicadores componentes. 18
Figura 2. Matriz de correlaciones entre los indicadores componentes del ICRU. 27
Figura 3. Biplot del análisis de componentes principales sobre el panel. 28
Figura 4. Dendrograma del análisis de conglomerados jerárquico (Ward, distancia euclídea)..... 29
Figura 5. Mapa de calor ICRU 2023. 32
Figura 6. Evolución del ranking de países según el ICRU (2014-2023). 35
Figura 7. Evolución por dimensiones de tres países representativos (Islandia, Chequia y Turquía). 36
Figura 8. Comparación entre el ICRU principal y la especificación con ponderación igualitaria. 36
Figura 9. Comparación entre el ICRU principal y la especificación con ponderación igualitaria (2023). 37
Figura 10. Comparación entre el ICRU principal y la agregación geométrica (panel 2014-2023). 37
Figura 10. Comparación entre el ICRU 2023 y PIB. 39
Figura 11. Matriz de correlación de valores faltantes. 73
Figura 12. Visualización ICRU x. ICRU_eq. 74
Figura 13. Visualización ICRU_2023 x. ICRU_2023_eq. 74
Figura 14. Visualización ICRU x. ICRU_geom. 75
Figura 15. Visualización ICRU_2023 x. ICRU_2023_geom. 75
Figura 16. Evolución de ranking de países según ICRU. 76
Figura 17. Evolución de ranking de top 10 y bottom 10 países según ICRU. 76
Figura 18. Evolución de ICRU para subset de países. 77
Figura 19. Evolución por dimensiones de ICRU para subset de países. 77
Figura 20. Relación entre ICRU y GDP (2023). 78
Figura 21. Matriz de correlación de variables de ICRU. 78
Figura 22. Matriz de correlación de variables de ICRU_2023. 79
Figura 23. Análisis de PVE. 79
Figura 24. PCA biplot. 80
Figura 25. Matriz de distancia euclidiana. 80

Figura 26. Matriz de distancia Manhattan. 80
Figura 27. Matriz de distancia correlada. 81
Figura 28. Dendograma con distancia euclidiana y criterio Complete. 81
Figura 29. Dendograma con distancia euclidiana y criterio Ward. 82
Figura 30. Dendograma con distancia manhattan y criterio Complete. 82
Figura 31. Dendograma con distancia manhattan y criterio Ward. 83
Figura 32. Dendograma con distancia correlada y criterio Complete. 83
Figura 33. Dendograma con distancia correlada y criterio Ward. 84
Figura 34. Mapa de calor con dendograma. 85
Figura 35. Plot de clústeres. 85
Figura 36. Análisis de Silhouette – Ward con distancia euclidiana. 85
Figura 37. Centroides por cluster. 86

Índice de tablas

Tabla 1. Indicadores componentes del ICRU, descripción y unidad de medida. 20
Tabla 2. Estructura del panel de datos para ICRU. 23
Tabla 3. Comparación de los métodos de imputación según su error. 25
Tabla 4. Pesos de la dimensión de generación (ICRU). 30
Tabla 5. Pesos de la dimensión de gobernanza (ICRU). 30
Tabla 6. Ranking ICRU 2023. 33
Tabla 7. Puntiación por dimensión de top 5 y bottom 5, ICRU 2023. 34
Tabla 8. Variación media de posiciones de ICRU e ICRU 2023. 38
Tabla 9. Correlación de ICRU con ICRU agregado con pesos iguales. 73
Tabla 10. Correlación de ICRU_2023 con ICRU_2023 agregado con pesos iguales. . 74
Tabla 11. Correlación de ICRU con ICRU_geom. 75
Tabla 12. Correlación de ICRU_2023 con ICRU_2023_geom. 75
Tabla 13. Pesos de la dimensión de generación (ICRU). 86
Tabla 14. Pesos de la dimensión de tratamiento (ICRU). 87
Tabla 15. Pesos de la dimensión de gobernanza (ICRU). 87
Tabla 16. Pesos de la dimensión de impacto (ICRU). 87
Tabla 17. Pesos de la dimensión de generación (ICRU 2023). 88
Tabla 18. Pesos de la dimensión de tratamiento (ICRU 2023). 88

Tabla 19. Pesos de la dimensión de infraestructura (ICRU 2023). 88
Tabla 20. Pesos de la dimensión de gobernanza (ICRU 2023). 88
Tabla 21. Pesos de la dimensión de impacto (ICRU 2023). 89

Índice de fórmulas

Fórmula 1. Cálculo del Circular Economy Index. 12
Fórmula 2. Agregación del indicador ICRU. 16
Fórmula 3. Tratamiento de GEN2. 20
Fórmula 4. Tratamiento de GEN3. 20
Fórmula 5. Normalización min-max. 26
Fórmula 6. Inversión de la orientación de las variables. 26
Fórmula 7. Cálculo de los pesos mediante PCA. 29
Fórmula 8. Agregación de los indicadores en cada dimensión. 31
Fórmula 9. Agregación final del ICRU (media aritmética de las dimensiones). 31

1. Introducción

El objetivo del presente proyecto es crear un indicador compuesto que mida cómo de bien gestiona cada país sus residuos urbanos. Esto nos permitirá comparar el desempeño de países entre sí y también estudiar su evolución. Antes de empezar con la construcción del indicador, que llamaremos Indicador de Circularidad de Residuos Urbanos (ICRU), conviene dar un poco de contexto y repasar el estado del arte.

1.1 Contexto general: transición hacia la economía circular en la Unión Europea

Históricamente, la gestión de los recursos y los residuos se ha basado siempre en un modelo lineal de producción y consumo. Todo empieza con la extracción de la materia y los recursos, y esta va seguida de la transformación, el uso y la eliminación final (van Buren et al., 2016). Siguiendo este modelo, los residuos son un subproducto inevitable del proceso económico, y su destino final el vertedero o la incineración. Este modelo ha permitido e impulsado altos niveles de producción y consumo, pero a la vez ha tenido consecuencias gravísimas como el agotamiento de recursos naturales, el aumento de emisiones contaminantes y una presión insostenible sobre los sistemas de gestión de residuos.

Así surge el modelo de economía circular, que ha ido cobrando cada vez más protagonismo en las últimas décadas. El objetivo de este modelo, en palabras de van Buren et al. (2016), es acabar con la destrucción innecesaria de recursos mediante una reducción del consumo de materia prima, un diseño de productos que permita su futura reutilización, la prolongación del ciclo de vida de los productos mediante mantenimiento y reparación, y el uso de materiales reciclables unido a la recuperación de materias primas en los flujos de residuos.

La Unión Europea ha dedicado esfuerzos considerables a impulsar una transición del modelo de *"take-make-waste"* (van Buren et al., 2016), a una economía circular, con iniciativas como el Pacto Verde Europeo. Con esto la UE pretende alcanzar, entre otras cosas, un diseño ecológico de productos, estableciendo requisitos de sostenibilidad medioambiental para casi todos los productos, o implantando un nuevo pasaporte digital de productos. Asimismo, se busca aumentar el ciclo de vida de los productos, reforzando y garantizando el derecho de los consumidores a la reparación, y se persigue reducir las emisiones de los procesos productivos y la industria.

Como se puede observar, la economía circular es un concepto multidimensional, y por ello tiene sentido que el estudio del grado de adopción de un país de este modelo económico

y social se haga teniendo en cuenta una gran variedad de indicadores, y no solo un simple porcentaje de residuos reciclados.

1.2 Marco normativo europeo y plano nacional

Aunque se ha mencionado brevemente en el apartado anterior, conviene entrar más en profundidad en el marco normativo europeo para entender la importancia que se le da a la economía circular.

1.2.1 Marco normativo europeo

La Unión Europea ha ido desarrollando su política en materia de residuos de forma progresiva desde principios del siglo XXI. De esta forma, ha ido creando un marco normativo cada vez más y más robusto y ambicioso que en sus orígenes buscaba reducir emisiones y disminuir y mejorar la gestión de los residuos, y actualmente es la punta de lanza para llegar a una circularidad total.

Como primer gran paso en este sentido cabe destacar la aprobación de la Directiva Marco de Residuos 2008/98/CE, que establece medidas destinadas a proteger el medio ambiente y la salud humana mediante la prevención o la reducción de los impactos adversos de la generación y gestión de los residuos, la reducción de los impactos globales del uso de los recursos y la mejora de la eficacia de dicho uso. La aportación clave de esta directiva fue la creación detallada de una jerarquía de residuos (art. 4 de la Directiva 2008/98/CE), que serviría de guía a los legisladores nacionales y crearía un sistema claro y unificado con el que afrontar el comienzo de lo que sería una auténtica transición medioambiental. Según esta jerarquía, se prioriza la prevención de la generación de residuos, seguida por su preparación para la reutilización, el reciclado, contemplándose después de esto otros tipos de valorización como puede ser la valorización energética, y por último la eliminación del residuo.

Paralelamente, la UE fue desarrollando una serie de directivas sectoriales destinadas a regular flujos de residuos específicos. Destacan la Directiva 94/62/CE sobre envases y residuos de envases, la Directiva 2012/19/UE sobre residuos de aparatos eléctricos y electrónicos y la Directiva 2006/66/CE relativa a pilas y acumuladores. Todo esto creaba una sólida base sobre la que implantar y construir el concepto de una economía circular.

Llega entonces el verdadero punto de inflexión cuando en 2015 la Comisión Europea presenta el Plan de Acción para una economía circular en Europa (Comisión Europea, 2015). Esta iniciativa abarca todo el ciclo económico y está compuesta por un total de 54 medidas

sobre las que la CE estimó necesario actuar en los 5 años siguientes a la aprobación de la directiva. Estas medidas tocaban de forma vertical todas las etapas del ciclo de vida de los productos, y de forma transversal cinco áreas que la Comisión consideró prioritarias: los plásticos, el desperdicio alimentario, las materias primas críticas, la construcción y la demolición y la biomasa y productos con base biológica. Este paquete de medidas fue sustancialmente revisado en 2018 (Comisión Europea, 2018a), y con ellos la UE dio un paso decisivo para pasar de una política centrada en la gestión de residuos a una política orientada a la eficiencia sistémica y al cierre de los ciclos de materiales.

En 2019 se aprueba el Pacto Verde Europeo (Comisión Europea, 2019), un proyecto que integra la transición hacia una economía circular en un proyecto que también fija otras metas medioambientales como por ejemplo la neutralidad climática, el establecimiento de prácticas agrícolas más sostenibles. Según García Lupiola (2022), el Pacto Verde Europeo es una hoja de ruta para hacer que la economía de la UE sea sostenible, transformando los retos en materia de clima y medio ambiente en oportunidades. En palabras de Fernández de Gatta Sánchez (2020), el PVE constituye "el proyecto de política medioambiental más ambicioso de la historia europea".

1.2.2 Plano nacional

El marco normativo descrito ha sido implementado por los estados miembros y se ha traducido en prácticas e iniciativas a nivel nacional. No obstante, los datos muestran que los efectos de la implementación de este marco normativo no han sido homogéneos ni lineales. Existen por un lado diferencias estructurales entre los países en cuanto a la cantidad de residuos generados, y a su vez existen diferencias en cuanto a las prácticas de tratamiento utilizadas (REtema, s. f.). A modo de ejemplo, los residuos municipales por persona fueron más altos en países como Austria, Luxemburgo, Dinamarca, y Bélgica, mientras que en países como España, Croacia, Letonia y Suecia vemos cifras inferiores. Podemos ver por lo tanto que, a pesar de haber una normativa homogénea a nivel europeo, hay muchos otros factores que afectan a cómo de avanzados están los países en materia de economía circular.

1.3 Estado del arte: indicadores y metodologías existentes

Por último, antes de empezar con la construcción del ICRU, procede hacer un estudio del estado del arte. Investigaremos por lo tanto los indicadores compuestos existentes en materia de economía circular, para justificar así por qué el ICRU es innovador y aporta valor a la cuestión.

1.3.1 Circular Economy Monitoring Framework

Como base conviene mencionar el Circular Economy Monitoring Framework (CEMF) (Comisión Europea, 2018b). No es un indicador compuesto como tal, pero sí es un conjunto de indicadores que sirven para monitorizar el progreso hacia una economía circular en la UE. El CEMF se estructura en cinco áreas temáticas y está compuesto por once indicadores estadísticos. Producción y Consumo es la primera área temática del CEMF, y se centra en analizar la fase de producción y consumo, que es considerada uno de los principales focos de presión ambiental en la economía actual. La producción y el consumo no solo aumentan la cantidad de residuos y agotan las reservas de recursos naturales, sino que están estrechamente ligadas a una parte sustancial de las emisiones de gases de efecto invernadero, la degradación de ecosistemas y la presión sobre los recursos hídricos.

La siguiente área temática se centra en la gestión de los residuos generados. El reciclaje de residuos cierra los ciclos de materiales y evita la pérdida de valor final del proceso económico. Si los residuos no se reciclan, no solo se pierden los materiales sino también la energía incorporada y los recursos empleados en su extracción, transformación y fabricación. Esta dimensión integra dos indicadores estadísticos, uno relativo a las tasas agregadas de reciclaje, y otro correspondiente a tasas de reciclaje de flujos de residuos específicos, como envases o residuos electrónicos.

La siguiente dimensión que crea la Comisión Europea en su CEMF (2018) es la de las materias primas secundarias, que esencialmente son materiales recuperados a partir de residuos y que pueden sustituir a materias primas vírgenes en los procesos productivos. El marco adopta dos indicadores estadísticos en esta dimensión. En primer lugar, evalúa la contribución de los materiales reciclados a la demanda total de materia prima, que mide en qué medida la economía es capaz de abastecer los ciclos productivos usando materiales reciclados en lugar de materias primas vírgenes. Este indicador se desglosa en dos subindicadores, por un lado la tasa de uso circular de materiales, que captura esta contribución a nivel agregado de toda la economía, y por otro las tasas de reciclaje al final de la vida útil, que evalúan el grado de recuperación de materiales específicos considerados estratégicos o de especial relevancia económica y ambiental. El segundo indicador que utiliza esta dimensión del CEMF desarrollado por la Comisión Europea (2018) es el comercio de materias primas reciclables, no solo a nivel de la UE sino a nivel global. Este indicador es clave para estudiar la capacidad de los países de convertir los residuos generados en materias primas secundarias.

La cuarta dimensión es la competitividad y la innovación. Desde esta perspectiva, la economía circular no se percibe solo como una estrategia medioambiental, sino que se le da una importancia económica ya que en cierto modo permite reforzar la competitividad económica mediante el aumento de la vida útil de los productos, la mejora de su diseño y la adopción de nuevos modelos de producción y consumo. Esta área temática está compuesta por dos indicadores principales. En primer lugar, se analizan las inversiones privadas, el empleo y el valor añadido bruto vinculados a sectores clave de la economía circular, entre los que destacan el reciclaje, la reparación y la reutilización. El segundo indicador se centra en medir el grado de innovación, a través del número de patentes relacionados con el reciclaje y materias primas secundarias.

Por último, se dedica una dimensión a estudiar la sostenibilidad global y la resiliencia del sistema económico europeo. Esta dimensión emplea dos indicadores que a su vez se componen de dos subindicadores cada uno. Por una parte, se mide la sostenibilidad global del sistema, compuesta por un subindicador que refleja la huella de consumo y permite evaluar hasta qué punto se respetan los límites planetarios, y otro subindicador que mide las emisiones de gases efecto invernadero asociadas a las actividades productivas. Por otra parte, se mide la resiliencia del sistema económico a través de un subindicador que mide la dependencia de importaciones de materias primas, y otro que mide la autosuficiencia que evalúa la capacidad interna de abastecimiento para los procesos productivos.

El CEMF desarrollado por la Comisión Europea (2018) es un sistema completo y coherente de indicadores individuales agrupados en dimensiones que busca analizar cómo de avanzada está la UE en el camino hacia una economía circular. Habiéndolo analizado, hemos podido ver que evaluar el grado de adopción de una economía circular no es tarea fácil, que deben tenerse en cuenta muchos factores, y que no es cuestión simplemente de analizar qué porcentaje de residuos son reciclados. Esto nos sitúa en una buena posición sobre la que empezar a construir el ICRU, y nos da una idea de qué posibles indicadores o dimensiones podemos usar.

1.3.2 Circularity Gap Report

El Circularity Gap Report (Circle Economy, 2025) es un informe realizado anualmente por la organización Circle Economy en colaboración con Deloitte que busca medir mediante una métrica el progreso hacia una economía circular. El indicador se centra en analizar en qué medida los materiales utilizados por una economía proceden de fuentes secundarias como pueden ser materiales recuperados y reciclados. El indicador se presenta como un valor

porcentual que proviene de la porción de materiales secundarios respecto del total de materiales usados en una economía en un periodo determinado. Según esta métrica, en 2018 la economía global era únicamente un 9,1% circular (Circle Economy, 2018). Este número ha llegado en 2025 a un 6,9% (Circle Economy, 2025), indicando un empeoramiento en los niveles de circularidad globales.

Pese a su fácil interpretabilidad y su utilidad, el Circularity Gap Report no sustituye a un indicador compuesto como el ICRU, ya que se centra exclusivamente en los flujos materiales, y no tiene en cuenta otras dimensiones como pueden ser la inversión institucional o la infraestructura nacional que son claves a la hora de analizar cómo de preparado está un país para adoptar un sistema completamente circular.

1.3.3 Circular Economy Index

Otro indicador que conviene mencionar es el Circular Economy Index desarrollado por Di Maio y Rem (2015). Este indicador surge como crítica a los indicadores tradicionales que se centran en extraer conclusiones de cálculos hechos con la cantidad de masa reciclada, y proponen como alternativa tener en cuenta el valor económico y ambiental de los materiales. De esta forma, los autores argumentan que se tomarían decisiones más eficientes y se fomentaría el desarrollo de tecnologías que permitan recuperar materiales escasos o de gran impacto medioambiental, en lugar de incentivar únicamente el reciclaje de grandes volúmenes de materiales.

El CEI es el cociente que tiene por numerador el valor económico de los materiales recuperados tras el reciclaje de un producto al final de su vida útil, y por denominador el valor económico de mercado de todos los materiales que serían necesarios para volver a fabricar ese mismo producto.

$$CEI = \frac{Material\ value\ recycled\ from\ EOL\ product\ (s)}{Material\ value\ needed\ for\ (re-)\ producing\ EOL\ product\ (s)}$$

Fórmula 1. Cálculo del Circular Economy Index.

El CEI puede calcularse a nivel de producto, a nivel sectorial o a nivel empresarial. Esta es la principal razón por la que no sustituye a un indicador compuesto a nivel estatal capaz de comparar el desempeño de distintos países. El nivel de detalle requerido para calcular el CEI hace prácticamente imposible conseguir una cifra a nivel nacional. En segundo lugar, el CEI se centra exclusivamente en el proceso de reciclaje, sin integrar dimensiones clave como la generación de residuos, que representa la presión inicial que sufre el sistema, la

infraestructura disponible o la inversión institucional. Por todo esto, el CEI no actúa como un indicador capaz de evaluar el grado de adopción de un sistema circular a nivel nacional que integre todas las dimensiones relevantes en este ámbito.

1.3.4 Composite Circularity Index

El Composite Circularity Index desarrollado por Garrido et al. (2023) es un auténtico indicador sintético que mide a nivel microeconómico el grado de adopción de un sistema circular que presenta una unidad de negocio concreta, como puede ser un hotel. Los indicadores componentes son indicadores cualitativos medidos mediante escalas ordinales, mediante los cuales el propio negocio mide su grado de adopción de distintas prácticas circulares alineadas con el Plan de Acción para la Economía Circular de la Comisión Europea (2020). Todos estos indicadores componentes se ponderan y agregan utilizando un modelo de Benefit of the Doubt, desarrollado inicialmente por Lovell et al. (1995), basado en Data Envelopment Analysis.

El enfoque de BoD constituye un modelo de agregación muy útil y popular en la construcción de indicadores compuestos sobre todo cuando no existe un consenso previo relativo a la ponderación de los indicadores. En palabras de Garrido et al. (2023), el modelo de BoD permite evaluar cada unidad de observación, ya sea un hotel o un país de la UE en un año determinado, bajo la mejor luz posible, al ofrecer plena flexibilidad en la elección de los pesos asociados a los indicadores componentes.

El Composite Circularity Index es un ejemplo perfecto de cómo construir un indicador compuesto. Sin embargo, no propone una alternativa a lo que pretendemos que sea el ICRU, ya que se centra en unidades de negocio y no en países.

1.3.5 Sustainable Circular Index

Otro indicador que merece la pena mencionar el Sustainable Circular Index de Azevedo, Godina y Matias (2017). Consiste en un indicador que evalúa de forma integrada el grado de sostenibilidad y circularidad de empresas manufactureras. Consta de cuatro dimensiones que son: sostenibilidad económica, social, ambiental, y una última dimensión específica de circularidad. Es una herramienta útil para que las empresas evalúen su desempeño circular y sostenible y se comparen con otras organizaciones.

Aunque en cuanto a las dimensiones y los subindicadores empleados no es de especial interés para la construcción del ICRU y no propone una alternativa viable, metodológicamente presenta ciertos elementos importantes a la hora de construir un

indicador compuesto como pueden ser la normalización a través del min-max y la agregación a través del método Delphi, y que nos serán útiles cuando llegue el momento de crear el ICRU.

1.3.6 Material Circularity Indicator

El *Material Circularity Indicator* de la Ellen MacArthur Foundation (2015), es una herramienta utilizada para medir en qué medida un producto o una empresa mantiene los materiales en uso dentro del sistema económico, evitando así utilizar materias primas vírgenes para producir sustitutos. Se calcula a raíz de la proporción de materiales secundarios utilizados en la fabricación de un producto, la fracción de materiales que se recuperan al final de su vida útil y la duración efectiva del producto en comparación con un escenario de referencia. Es un indicador referencial que aparece citado en cantidad de proyectos en materia de indicadores compuestos de circularidad, y sin embargo no propone una alternativa viable al ICRU, ya que se centra en el estudio de productos o empresas concretas, y no países.

Vemos por lo tanto que no existe un indicador que estudie el progreso de países a lo largo del tiempo hacia una economía circular, integrando información no solo de los flujos materiales sino de otras dimensiones clave como las inversiones institucionales, la infraestructura pública o las importaciones y exportaciones de residuos. Los indicadores existentes se centran exclusivamente en el flujo material, o trabajan a una escala muy granular y estudian empresas concretas, productos o sectores.

1.4 Motivación y aportación del Indicador de Circularidad de Residuos Urbanos (ICRU)

Una vez estudiado el estado del arte, podemos comprobar que no hay ninguna herramienta que mida el grado de adopción de una economía circular que presentan los países, y que lo haga integrando los distintos ámbitos claves que se deberían tener en cuenta. Hemos visto indicadores que miden la proporción de materia prima secundaria que se usa de input en los procesos productivos, pero que no tienen en cuenta cuánto residuo se ha producido, cuántas emisiones se han generado a la hora de tratar esos residuos o si la mayoría de esos residuos se han exportado a otros países o se han tratado de forma local.

A pesar de los esfuerzos del legislador europeo, vemos que según algunos índices la circularidad está en declive (Circle Economy, 2025). Es por esto por lo que es más

importante que nunca tener una herramienta que nos permita analizar la circularidad de los países, estudiar su evolución, compararlos entre sí, y que integre dimensiones de forma coherente y estructurada para poder identificar las causas del buen o mal rendimiento de determinados países, y así mejorar y acercarnos más a una economía completamente circular.

1.5 Objetivos del trabajo

El objetivo general de este trabajo es el diseño y la construcción de un indicador compuesto, el Indicador de Circularidad de Residuos Urbanos (ICRU), que permita medir, de forma robusta y comparable, el grado de circularidad alcanzado por los distintos países europeos en la gestión de sus residuos urbanos, integrando en un único valor las múltiples dimensiones que intervienen en dicho proceso.

Para alcanzar este objetivo general se plantean los siguientes objetivos específicos: (i) definir un marco conceptual que identifique las dimensiones relevantes de la circularidad de los residuos urbanos y seleccionar, a partir de fuentes oficiales, los indicadores que las representan; (ii) construir una base de datos coherente y comparable entre países, abordando el tratamiento de los valores ausentes; (iii) aplicar una metodología rigurosa de normalización, ponderación y agregación, apoyada en el análisis de la estructura estadística de los datos; (iv) evaluar la robustez del indicador frente a las distintas decisiones metodológicas adoptadas y contrastar su validez con una referencia externa; y (v) obtener una clasificación de los países y analizar su evolución temporal, de modo que los resultados resulten útiles para el diagnóstico y la toma de decisiones en materia de economía circular.

1.6 Metodología general de construcción del índice

La construcción del ICRU sigue la metodología de referencia para la elaboración de indicadores compuestos recogida en el manual de la OCDE y el Joint Research Centre (OCDE, 2008). Dicha metodología plantea un proceso secuencial en el que cada etapa condiciona a las siguientes: definición del marco teórico, la selección de las variables y la depuración de los datos, el tratamiento de los valores ausentes, el análisis multivariante de la estructura de la información, la normalización de las variables para hacerlas comparables, su ponderación y posterior agregación en un índice único y, finalmente, el análisis de la robustez del resultado.

Este proceso se ha implementado combinando dos entornos de programación complementarios. El tratamiento de los datos, la imputación, la normalización, la ponderación, la agregación y los análisis de robustez y validación se han desarrollado en

Python, mientras que el análisis multivariante (el estudio de las correlaciones, el análisis de componentes principales y la agrupación de los países) se ha realizado en R, aprovechando sus librerías especializadas. Asimismo, el indicador se ha construido en dos versiones: un panel temporal que cubre el periodo 2014-2023, que permite estudiar la evolución de la circularidad, y un corte transversal correspondiente al año 2023, que incorpora un mayor número de dimensiones gracias a la mayor disponibilidad de datos para ese año.

Cada una de estas etapas se desarrolla en detalle en los capítulos siguientes: el capítulo 2 presenta el diseño conceptual del indicador, el capítulo 3 aborda su construcción y el capítulo 4 recoge los resultados, el análisis de robustez y la validación del ICRU.

2. Diseño conceptual del ICRU

2.1 Fundamentos metodológicos del indicador compuesto

Para construir el ICRU es necesario partir de una base metodológica sólida. Un indicador compuesto, o indicador sintético, puede definirse como una medida construida a partir de la combinación de múltiples indicadores individuales, denominados de aquí en adelante indicadores componentes, que carecen, por sí solos, de una unidad común de medida (Freudenberg, 2003). Su utilidad reside precisamente en su capacidad para resumir fenómenos multidimensionales difíciles de capturar mediante un único valor, ofreciendo una cifra agregada que facilita la comparación entre unidades de observación y el seguimiento de su evolución en el tiempo (Nardo et al., 2005).

Como se ha argumentado en la introducción, la economía circular constituye un fenómeno marcadamente multidimensional, por lo que su medición no puede reducirse a un único porcentaje de reciclaje. En este sentido, el indicador compuesto se presenta como la herramienta idónea para sintetizar, en un solo índice, las distintas dimensiones que intervienen en la gestión circular de los residuos urbanos.

En su forma más habitual, un indicador compuesto se obtiene mediante la agregación ponderada de sus indicadores componentes, previamente normalizados. Siguiendo un esquema de agregación aritmética, el valor del índice para una unidad de observación puede expresarse como:

$$ICRU = \sum_{i=1}^{n} w_i I_i$$

Fórmula 2. Agregación del indicador ICRU.

donde I_i representa el valor normalizado del indicador componente i, w_i el peso asociado a dicho indicador y n el número total de indicadores considerados. A lo largo del trabajo se presentarán otras expresiones correspondientes a las distintas técnicas de normalización, ponderación y agregación empleadas.

La construcción de un indicador compuesto, sin embargo, no se reduce a esta fórmula final. Se trata de un proceso secuencial en el que cada fase condiciona a las siguientes y en el que cada decisión metodológica debe estar debidamente justificada. La presente memoria sigue las recomendaciones del manual de referencia en la materia, elaborado por la OCDE junto al Joint Research Centre (OCDE, 2008), que estructura la elaboración de un indicador sintético en una serie de etapas sucesivas: la definición de un marco conceptual, la selección y depuración de los datos, el tratamiento de los valores ausentes, el análisis multivariante de la estructura de los datos, la normalización de las variables, su ponderación y agregación y, por último, el análisis de la robustez del índice resultante.

Conviene subrayar que algunas de estas decisiones, en particular las relativas a la ponderación y la agregación, concentran buena parte de la discrecionalidad del proceso y, por tanto, de la incertidumbre asociada al resultado. Por ello, la literatura insiste en la importancia de acompañar todo indicador compuesto de un análisis de robustez que evalúe en qué medida los resultados dependen de las opciones metodológicas adoptadas (Greco et al., 2019). Estas fases, descritas aquí en términos generales, se desarrollan y aplican al caso concreto del ICRU en los capítulos siguientes.

2.2 Definición de las dimensiones del ICRU

El primer paso en la construcción del ICRU consiste en definir las dimensiones que lo integran. Frente a un enfoque puramente estadístico, en el que la agrupación de los indicadores se derivaría exclusivamente de sus correlaciones, la definición de las dimensiones del ICRU responde a un criterio conceptual, fundamentado en la lógica del propio proceso de gestión de los residuos urbanos y alineado con el marco analítico de la economía circular europea, en particular con el Circular Economy Monitoring Framework (Comisión Europea, 2018) y con la jerarquía de residuos establecida en la Directiva 2008/98/CE. El análisis multivariante que se presenta más adelante se emplea como herramienta exploratoria para comprender la estructura de los datos, pero no como criterio último de agrupación, priorizando así la interpretabilidad y la relevancia para el análisis de políticas.

Bajo este criterio, los indicadores se organizan siguiendo las etapas del ciclo de gestión de los residuos urbanos. La dimensión de generación recoge la presión inicial que recibe el sistema, esto es, el volumen de residuos producidos, su intensidad respecto a la población y a la actividad económica, y su composición. La dimensión de tratamiento refleja el funcionamiento efectivo del sistema de gestión, es decir, cómo se procesan los residuos una vez generados y en qué medida el país recupera material en lugar de eliminarlo. La dimensión de infraestructura captura la capacidad física que sostiene las prácticas circulares, medida a través de la dotación de contenedores y puntos de recogida por habitante y por superficie. La dimensión de gobernanza integra los aspectos institucionales y económicos del sector, fundamentalmente el esfuerzo público destinado a la gestión de residuos. Por último, la dimensión de impacto medioambiental mide las consecuencias ambientales asociadas al tratamiento de los residuos. La Figura 1 resume esta estructura.

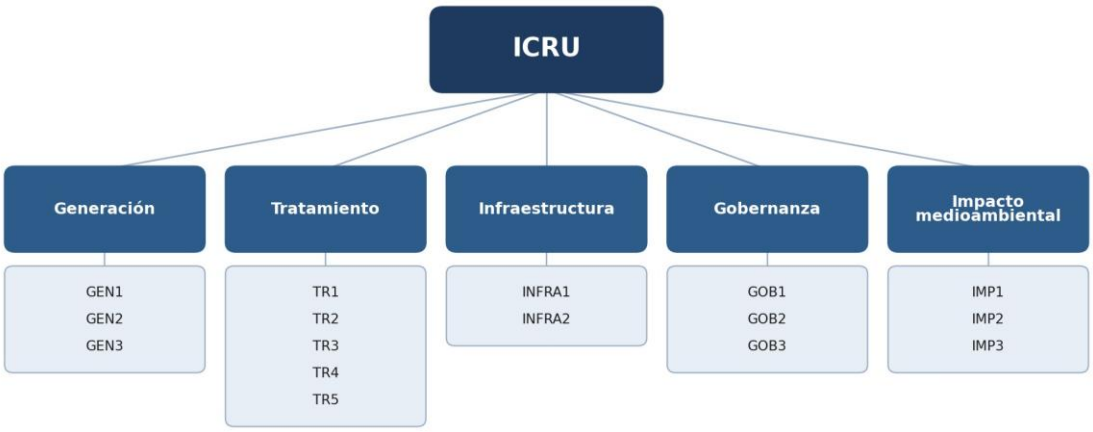


Figura 1. Estructura conceptual del ICRU: dimensiones e indicadores componentes.

Esta estructura no se aplica de forma idéntica a las dos versiones del indicador que se construyen en este trabajo. Dado que los datos de infraestructura física solo se encuentran disponibles para el año 2023, la dimensión de infraestructura únicamente puede operacionalizarse en el corte transversal de dicho año. De este modo, el índice temporal se articula en cuatro dimensiones (generación, tratamiento, gobernanza e impacto), mientras que el corte de 2023 incorpora además la de infraestructura, aprovechando la mayor riqueza informativa disponible para ese año.

2.3 Selección y definición de las variables

Una vez definidas las dimensiones, procede seleccionar los indicadores componentes que las integran. La práctica totalidad de los datos empleados en el ICRU procede de Eurostat, la oficina estadística de la Unión Europea, lo que garantiza la homogeneidad, la comparabilidad y la trazabilidad de la información entre los distintos países y años considerados. La única excepción son los indicadores de infraestructura incorporados en la versión de 2023 del índice, que proceden de OpenStreetMap (OSM) y cuyo tratamiento se detalla más adelante.

Con el fin de organizar las variables de forma sistemática, se ha adoptado una nomenclatura basada en el código de la dimensión seguido de un número de orden; así, por ejemplo, la primera variable de la dimensión de generación se denomina GEN1. La Tabla 1 recoge los dieciséis indicadores componentes del ICRU, junto con su descripción y su unidad de medida.

Código	Descripción	Unidad
Generación		
GEN1	Residuos municipales generados per cápita	kg/hab
GEN2	Residuos municipales por unidad de PIB	kg / miles € PIB
GEN3	Residuos reciclables o biodegradables sobre el total generado	% del total
Tratamiento		
TR1	Reciclaje material	% del total
TR2	Compostaje y digestión anaerobia	% del total
TR3	Recuperación energética (incineración con R1)	% del total
TR4	Tasa de uso circular de materiales (CMU)	%
TR5	Balance neto de comercio de residuos para recuperación	kg/hab
Infraestructura		
INFRA1	Contenedores de residuos por superficie	Nº / 100 km²
INFRA2	Contenedores de residuos por habitante	Nº / 100 000 hab
Gobernanza		
GOB1	Gasto público en gestión ambiental per cápita	€/hab
GOB2	Empleo en el sector de gestión de residuos	FTE / 100 000 hab
GOB3	Valor añadido del sector de gestión de residuos	% del PIB
Impacto medioambiental		

IMP1	Emisiones de GEI del sector residuos per cápita	kg/hab
IMP2	Residuos depositados en vertedero	% del total
IMP3	Incineración sin recuperación de energía (D10)	% del total

Tabla 1. Indicadores componentes del ICRU, descripción y unidad de medida.

Buena parte de estos indicadores no se obtiene directamente de Eurostat, sino que resulta de transformaciones realizadas a partir de variables auxiliares, con el objetivo de expresarlos en términos relativos y comparables entre países. Así, por ejemplo, la intensidad de generación de residuos respecto a la actividad económica (GEN2) se obtiene relacionando los residuos generados per cápita con el producto interior bruto pasado a miles de euros:

$$GEN2 = \frac{GEN1 \cdot HAB}{GDP \cdot 1000}$$

Fórmula 3. Tratamiento de GEN2.

De forma análoga, los indicadores expresados como porcentaje del total de residuos generados, como la proporción de residuos reciclables (GEN3) o las distintas tasas de tratamiento, se calculan dividiendo la variable auxiliar correspondiente entre los residuos municipales totales:

$$GEN3 = \frac{AuxGEN3}{GEN1} \cdot 100$$

Fórmula 4. Tratamiento de GEN3.

A diferencia del resto de indicadores del ICRU, los dos indicadores de infraestructura (INFRA1 e INFRA2) no proceden de fuentes estadísticas oficiales, ya que Eurostat no ofrece una medida directa y comparable de la infraestructura física disponible para la recogida selectiva en cada país. Por ello se recurrió a OpenStreetMap (OSM) como fuente complementaria de datos geoespaciales, contabilizando los objetos etiquetados como puntos de reciclaje (amenity=recycling).

La primera idea fue construir una serie temporal de estos puntos para incorporarla al panel dinámico del índice, pero se descartó: el fuerte crecimiento observado año tras año no reflejaba la instalación real de nuevos contenedores, sino el progresivo aumento de la cobertura y la intensidad de mapeo de la propia comunidad de OSM. Para aislar y corregir ese sesgo de adopción se diseñó una estrategia basada en una categoría de infraestructura que apenas varía en el tiempo, los lugares de culto (amenity=place_of_worship). El razonamiento era el siguiente: dado que el número real de iglesias y templos de un país no se multiplica en una década, todo el crecimiento que OSM muestra en esta categoría puede

atribuirse al aumento del grado de adopción del mapa. La tasa de crecimiento de los lugares de culto serviría así como estimación del avance en la cobertura de OSM, de modo que, restando ese componente al crecimiento observado en los puntos de reciclaje, podría reconstruirse la serie histórica real de contenedores hacia atrás partiendo de los datos actuales, que son los más completos y fiables.

Sin embargo, al aplicar esta corrección la serie seguía mostrando un crecimiento demasiado pronunciado para ser plausible, y las transformaciones adicionales que se ensayaron para suavizarla introducían un grado de arbitrariedad difícil de justificar empíricamente. Se concluyó por tanto que comparar países en un único año reciente era mucho más defendible que reconstruir su evolución histórica, por lo que los indicadores de infraestructura se incorporan solo en la versión estática del índice (ICRU 2023), referida al año 2023.

El número de puntos de reciclaje por país se obtuvo mediante la API de ohsome, que permite fijar el estado del mapa en una fecha de referencia (31 de diciembre de 2023), automatizando la extracción mediante un script que para cada país de la Unión Europea contabilizaba los objetos amenity=recycling.

Conviene precisar que esta variable no constituye un inventario administrativo oficial, sino una aproximación a la infraestructura visible y mapeada en OpenStreetMap.

Por último, conviene anticipar que no todos los indicadores se orientan en la misma dirección respecto a la circularidad: mientras que algunos reflejan un mejor desempeño cuanto mayor es su valor (por ejemplo, las tasas de reciclaje), otros (como la generación de residuos, el vertido o las emisiones) representan resultados no deseables. El tratamiento de esta orientación, necesario para garantizar la coherencia interna del índice, se aborda en la fase de normalización.

3. Construcción del ICRU

Una vez definido el marco conceptual del ICRU, este capítulo describe el proceso seguido para su construcción, conforme a las etapas metodológicas presentadas en el apartado 1.6. Cada sección aborda una fase del proceso: la construcción de la base de datos, el tratamiento de los valores ausentes, la normalización y orientación de las variables, el análisis multivariante de su estructura y, finalmente, la ponderación y agregación que dan lugar al índice.

3.1 Construcción de la base de datos

Gran cantidad de la información empleada proviene de Eurostat, mientras que los datos del número de contenedores provienen de OpenStreetMap. Dado que cada indicador se obtiene de una base de datos distinta, el primer paso consistió en descargar cada una de ellas, darles un formato común de panel, con una fila por país y año, y combinarlas posteriormente en un único conjunto de datos. Este formato resulta imprescindible para poder trabajar de forma simultánea con la dimensión geográfica y la temporal del indicador.

A continuación, se depuró el conjunto resultante. Esta limpieza se realizó de forma manual, abriendo el panel construido en el paso anterior e inspeccionando visualmente las entidades disponibles para detectar cuáles debían descartarse. Por un lado, se eliminaron las entidades geográficas que no se correspondían con países individuales, como los agregados supranacionales (la Unión Europea de 27 y de 28 miembros, el Espacio Económico Europeo o la Asociación Europea de Libre Comercio) o las subdivisiones y duplicados de un mismo país (como Metropolitan France, Northern Ireland o Germany including former GDR). Por otro lado, se descartaron los países ajenos al ámbito de estudio, como Rusia, Ucrania o el Reino Unido, junto con aquellos cuyas series aparecían prácticamente vacías al revisar el panel (rozando el 100% de ausencia de datos para cada observación), fundamentalmente microestados y países candidatos con una cobertura estadística muy escasa en Eurostat, como Andorra, Mónaco, San Marino, Liechtenstein, Kosovo, Albania, Bosnia y Herzegovina, Macedonia del Norte, Montenegro, Armenia, Azerbaiyán o Georgia.

Asimismo, se restringió el periodo de análisis a los años 2014 a 2023, descartando los ejercicios anteriores por la escasez de datos disponibles. El panel final está formado por 32 países europeos observados a lo largo de diez años, lo que supone un total de 320 observaciones.

Por último, varias de las variables no se encuentran directamente disponibles en Eurostat, sino que se derivan de variables auxiliares mediante transformaciones que las expresan en términos relativos y comparables entre países, tal y como se detalló en el apartado 2.3. En los casos en que una variable derivada depende de una variable auxiliar ausente, el valor resultante se marca igualmente como ausente, de modo que la falta de información se propaga de forma coherente y se trata en la fase siguiente.

Tras este proceso de descarga, formateo, combinación y depuración, el panel de datos queda estructurado de la siguiente manera. Se trata de un panel que combina la dimensión geográfica y la temporal, de modo que cada fila representa la observación de un país en un

año concreto y, por tanto, cada país aparece en tantas filas como años se analizan. Las dos primeras columnas identifican la observación, el país (GEO) y el año (Year), mientras que las columnas restantes recogen el valor de cada uno de los indicadores para esa combinación de país y año. Con 32 países observados a lo largo de diez años (2014 a 2023), el panel resultante contiene 320 filas y una columna por cada variable del índice, tal y como se ilustra a continuación.

GEO	Year	GEN1	GEN2	GEN3	TR1	…	IMP3
Austria	2014	…	…	…	…	…	…
Austria	2015	…	…	…	…	…	…
…	…	…	…	…	…	…	…
Austria	2023	…	…	…	…	…	…
Bélgica	2014	…	…	…	…	…	…
…	…	…	…	…	…	…	…

Tabla 2. Estructura del panel de datos para ICRU.

La estructura del segundo indicador, el ICRU 2023, difiere de la anterior en dos aspectos derivados de su naturaleza estática. Por un lado, al referirse a un único año, desaparece la dimensión temporal: cada país aparece en una sola fila, por lo que el número de filas se reduce a una por país. Por otro lado, esta versión incorpora dos columnas adicionales respecto al panel temporal, INFRA1 e INFRA2, correspondientes a los indicadores de infraestructura procedentes de OpenStreetMap, que solo están disponibles para 2023 y que enriquecen el índice con una dimensión de infraestructura no presente en la versión temporal.

3.2 Tratamiento de los valores ausentes

Resulta conveniente precisar la estructura de datos sobre la que operan las técnicas de imputación, ya que de ella depende su correcto funcionamiento. La matriz de imputación se organiza de modo que cada fila corresponde a una observación país-año y cada columna a uno de los indicadores del índice; es decir, las observaciones de todos los países y años se apilan verticalmente, compartiendo un mismo conjunto de columnas. Esta disposición es la más natural e intuitiva para un panel de estas características, y además es la que permite que los algoritmos de imputación funcionen correctamente, ya que estos reconstruyen cada valor

ausente aprovechando la relación entre los distintos indicadores observados en esa misma fila, o lo que es lo mismo, en su mismo país para ese mismo año. Una estructura alternativa, en la que cada columna representara la combinación de un indicador y un país, fragmentaría la información en multitud de variables con muy pocas observaciones, y a mi juicio resultaría en una forma mucho menos intuitiva de organizar la información e incluso tratarla a la hora de programas los algoritmos de imputación.

La información temporal no se descarta, sino que se incorpora a la propia matriz mediante variables indicadoras (*dummies*) del año, en lugar de mantener el año como una única columna numérica. La razón es que, si el año se conservara como una variable continua, los algoritmos lo tratarían como una magnitud con orden y escala, asumiendo implícitamente que el efecto del tiempo es lineal y que la distancia entre dos años cualesquiera es siempre la misma. Codificarlo como un conjunto de variables *dummy* evita esa imposición: cada año se trata como una categoría independiente, lo que permite recoger un efecto temporal común a todos los países, como por ejemplo una mejora general de la circularidad en determinados años, sin forzar ninguna forma funcional concreta. El identificador de país, en cambio, no se incorpora como variable en la imputación. Esto no produce ninguna pérdida de información, porque en cierto modo el resto de los valores existentes en esa fila están condicionados por el país al que pertenecen.

Antes de imputar los datos ausentes, se realizó un estudio de su distribución por variable, país y año, con el objetivo de comprender su naturaleza y elegir el tratamiento más adecuado. Este análisis permitió distinguir dos situaciones diferentes: los huecos situados en los extremos de las series temporales y los huecos dispersos en el interior del conjunto.

Para el primer caso se observó que algunas variables, como GEN3 y GOB1, carecían de datos para el año 2023. Al tratarse de huecos al final de la serie, no era posible recurrir a la interpolación, por lo que se aplicó una técnica de predicción. En concreto, se utilizó el suavizado exponencial de Holt, apropiado para series que siguen una tendencia sostenida y no estacional, como suele ocurrir con los indicadores de gestión de residuos a escala nacional. Las series demasiado cortas o con huecos internos se reservaron para la fase de imputación posterior.

A continuación, se caracterizó el mecanismo que genera los datos ausentes. Para ello se aplicó el test de Little, que contrasta si los valores faltantes son completamente aleatorios (MCAR). Dado que este test asume normalidad multivariante, previamente se comprobó dicha hipótesis mediante el test de Mardia, que reveló desviaciones significativas respecto a la normalidad. Asumiendo el test de Little con la debida cautela, el resultado obtenido, con

un estadístico de 1209,47 y un p-valor inferior a 0,001, condujo a rechazar la hipótesis MCAR, lo que indica que los datos ausentes no son completamente aleatorios.

Para seleccionar el método de imputación se llevó a cabo una comparación empírica. Partiendo de un subconjunto completo de datos, se introdujeron valores ausentes de forma artificial y se imputaron mediante tres técnicas: el algoritmo de maximización de la esperanza (EM), la regresión lineal múltiple (MLR) y la imputación múltiple por ecuaciones encadenadas (MICE). La calidad de cada método se evaluó comparando los valores imputados con los originales a través de tres métricas de error: el error cuadrático medio (RMSE), el error absoluto medio (MAE) y la versión normalizada del primero (NRMSE), obtenida dividiendo el RMSE entre la media de los valores reales, lo que permite expresar el error en términos relativos e independientes de la escala de cada variable. La Tabla 3 recoge los resultados.

Método	RMSE	MAE	NRMSE
EM	15,43	11,30	0,373
MICE	15,29	11,35	0,369
MLR	17,12	12,95	0,414

Tabla 3. Comparación de los métodos de imputación según su error.

Los resultados muestran que MICE obtiene el menor error cuadrático medio (RMSE de 15,29), seguido muy de cerca por el algoritmo EM (15,43), mientras que la regresión múltiple presenta un rendimiento claramente inferior (17,12). No obstante, al atender al error absoluto medio se observa que EM es el método más preciso, con un MAE de 11,30 frente a los 11,35 de MICE y los 12,95 de la regresión múltiple. Dado que ambas técnicas ofrecen un rendimiento prácticamente equivalente, alternándose como mejor método según la métrica considerada, se optó por el algoritmo EM como método principal de imputación, por su mayor simplicidad, su carácter determinista y su amplia utilización en la literatura sobre indicadores compuestos.

Para interpretar la magnitud de estos errores conviene recordar que las variables están expresadas en una escala común de 1 a 100. Un RMSE en torno a 15 implica, por tanto, que el valor imputado se aparta de media unas quince unidades sobre cien respecto al real, lo que en términos relativos equivale a un error cercano al 37% del valor medio de los datos (NRMSE de 0,37). Se trata de un nivel de error moderado, esperable en un panel internacional donde los indicadores presentan una notable heterogeneidad entre países, y suficientemente contenido como para considerar fiable la imputación. Dado que MICE y EM ofrecen un rendimiento prácticamente equivalente, alternándose como mejor método

según la métrica considerada, se optó por el algoritmo EM como método principal de imputación, por su mayor simplicidad, su carácter determinista y su amplia utilización en la literatura sobre indicadores compuestos.

El corte transversal correspondiente al año 2023 recibió un tratamiento específico. Al disponer de un único año, no era posible aplicar técnicas temporales, por lo que sus valores faltantes de las variables de infraestructura se imputaron mediante regresión lineal múltiple a partir del resto de indicadores disponibles.

3.3 Normalización y orientación de las variables

Los indicadores componentes se expresan en unidades muy diversas (porcentajes, kilogramos por habitante, euros, etcétera) y no todos apuntan en la misma dirección respecto a la circularidad. Antes de agregarlos es necesario, por tanto, resolver dos cuestiones: homogeneizar sus escalas y unificar su orientación.

En primer lugar, para reducir la influencia de los valores extremos, cada variable se acotó a sus percentiles 5 y 95, operación conocida como winsorización. A continuación se aplicó una normalización de tipo mínimo-máximo, que reescala cada variable al intervalo comprendido entre 1 y 100:

$$v' = 1 + 99 \frac{v - v_{min}}{v_{max} - v_{min}}$$

Fórmula 5. Normalización min-max.

donde v representa el valor original, una vez acotado, v_{min} y v_{max} los mínimos y máximos que toma esa variable descontando los *outliers*, que son colapsados a 1 o 100, y v' el valor normalizado. Se ha optado por el intervalo entre 1 y 100, en lugar de entre 0 y 100, para evitar la presencia de ceros, que impedirían el uso de la agregación geométrica empleada más adelante en el análisis de robustez.

En segundo lugar, se unificó la orientación de las variables. En un indicador compuesto, todas las variables deben alinearse de modo que un valor más alto refleje siempre un mejor desempeño. Por ello, aquellas variables en las que un valor elevado representa un peor resultado, como la generación de residuos, el balance neto exportador de residuos, las emisiones, el vertido y la incineración sin recuperación, se invirtieron una vez normalizadas mediante la transformación:

$$v'' = 101 - v'$$

Fórmula 6. Inversión de la orientación de las variables.

de forma que, tras la inversión, también en estas variables un valor próximo a 100 corresponde a un buen desempeño en términos de circularidad.

3.4 Análisis multivariante

Una vez normalizadas y orientadas las variables, se analizó su estructura estadística con el doble objetivo de comprender las relaciones entre los indicadores y de fundamentar la posterior ponderación. Este análisis se realizó en R y se centró en el panel temporal, que ofrece un mayor número de observaciones.

El punto de partida fue la matriz de correlaciones (Figura 2). Su inspección revela patrones de asociación claros entre los indicadores, especialmente dentro del bloque de tratamiento, lo que confirma la existencia de una estructura interna suficiente para aplicar un análisis de componentes principales.

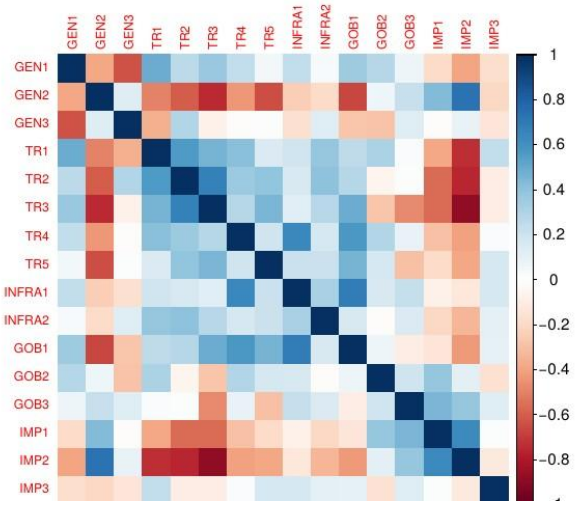


Figura 2. Matriz de correlaciones entre los indicadores componentes del ICRU.

Para verificar formalmente esta adecuación se aplicó el test de Kaiser-Meyer-Olkin (KMO). El panel obtiene un valor global de 0,70, considerado aceptable, si bien algunas variables presentan una adecuación muestral individual baja, en particular GOB2 e IMP3, en torno a 0,27. El corte de 2023, en cambio, arroja un KMO de 0,36, por debajo del umbral habitual de 0,60, con valores individuales uniformemente bajos; sus resultados, por tanto, deben interpretarse con especial cautela.

El análisis de componentes principales, aplicado sobre el panel, muestra que el primer componente explica el 39 % de la varianza, el segundo el 13 % y el tercero el 11 %, acumulando los tres en torno al 63 %. El biplot (Figura 3) facilita su interpretación: el primer componente opone los indicadores de tratamiento (TR1 a TR5 y GOB1) a los de presión

ambiental e intensidad de generación (IMP1, IMP2 y GEN2), configurando un eje que va del buen desempeño en reciclaje y recuperación al predominio del vertido y las emisiones.

El segundo componente, en cambio, no refleja el nivel de desempeño sino el modelo institucional del sector de residuos de cada país, distinguiendo dos perfiles diferenciados. En un extremo se sitúan los sistemas más tecnificados, caracterizados por un sector de residuos con mayor peso económico (GOB3) y un mayor potencial de valorización de los residuos, pero con un uso todavía persistente de la incineración sin recuperación energética (IMP3). En el extremo opuesto se encuentran los sistemas más intensivos en empleo (GOB2), menos tecnificados y con un perfil económico distinto. Este componente, por tanto, no separa a los países por su grado de circularidad, sino por la forma en que estructuran institucional y económicamente su gestión de residuos.

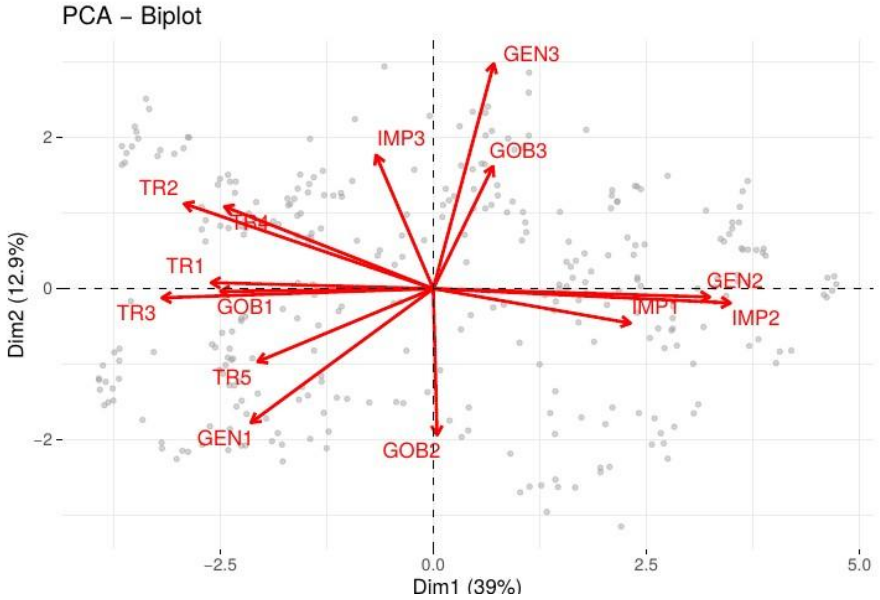


Figura 3. Biplot del análisis de componentes principales sobre el panel.

El análisis también identifica las variables peor integradas en la estructura común. GOB2 y GOB3 presentan cargas débiles, concentradas en los componentes secundarios, lo que concuerda con su baja adecuación en el test KMO; su aportación a la estructura latente resulta limitada. En conjunto, la dimensión de tratamiento es la más coherente desde el punto de vista estadístico, mientras que las de generación, gobernanza e impacto se reparten entre varios componentes, reflejando la complejidad estructural del sistema de residuos. Este resultado respalda la decisión de mantener una agrupación conceptual de las dimensiones, y no meramente estadística.

Por último, se realizó un análisis de conglomerados jerárquico, mediante el método de Ward con distancia euclídea, para explorar la posible existencia de grupos de países. El dendrograma (Figura 4) sugiere una división en dos grandes grupos. Sin embargo, el análisis de la silueta arroja una anchura media reducida, en torno a 0,26, y los grupos resultantes aparecen débilmente separados y poco interpretables. Más que en categorías nítidas, los países se distribuyen a lo largo de un continuo de desempeño en circularidad, en línea con el gradiente identificado por el primer componente principal.

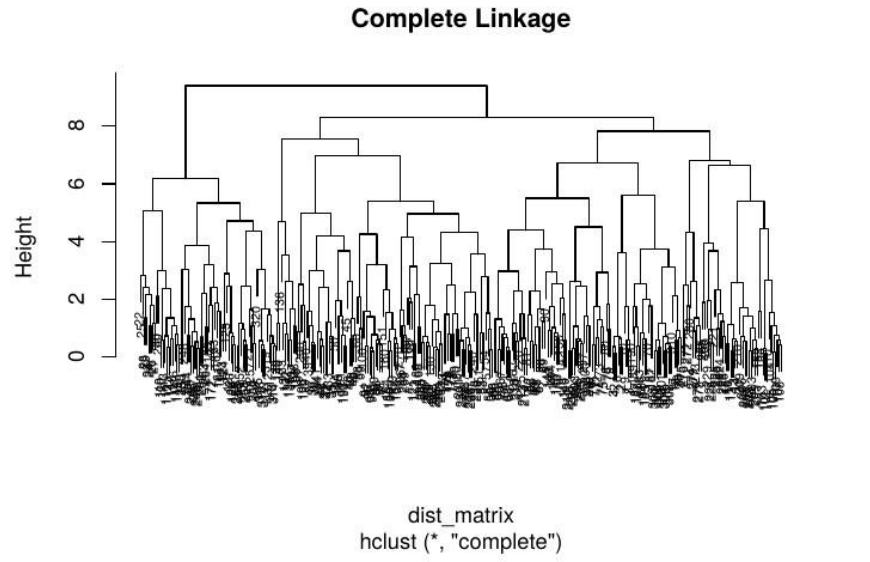


Figura 4. Dendrograma del análisis de conglomerados jerárquico (Ward, distancia euclídea).

3.5 Ponderación

Comprendida la estructura de los datos, el siguiente paso consistió en asignar un peso a cada indicador. Se ha optado por una ponderación basada en el *factor analysis*, uno de los métodos objetivos recomendados en la literatura (OCDE, 2008), aplicada en el interior de cada dimensión. Para cada dimensión se calcula su primer componente principal, suficiente para sintetizar dimensiones temáticamente homogéneas como las definidas, y se asigna a cada indicador un peso proporcional al cuadrado de su carga en dicho componente, normalizando los pesos para que sumen la unidad:

$$w_i = \frac{a_i^2}{\sum_i a_i^2}$$

Fórmula 7. Cálculo de los pesos mediante PCA.

donde a_i representa la carga del indicador i sobre el primer componente principal de su dimensión. De este modo, los indicadores que mejor recogen la variabilidad común de su

dimensión reciben un mayor peso. Como contrapartida, aquellos indicadores muy poco correlacionados con el eje principal de su dimensión reciben un peso próximo a cero, circunstancia que se discute entre las limitaciones del trabajo.

En cuanto a las dimensiones, se ha optado por otorgarles el mismo peso, de modo que ninguna prevalezca sobre las demás a priori. La combinación de ambos criterios se concreta en la fase de agregación.

La ponderación de los indicadores se realiza de forma independiente dentro de cada dimensión. El procedimiento consiste en extraer el primer componente principal de los indicadores estandarizados de la dimensión y asignar a cada uno un peso proporcional al cuadrado de su carga en dicho componente, normalizando después los pesos para que sumen la unidad. De este modo, los indicadores que más contribuyen a la señal común de la dimensión reciben un mayor peso. A modo de ejemplo, la siguiente tabla muestra los pesos obtenidos en las dimensiones de generación y gobernanza para el panel temporal (ICRU); el detalle completo de los pesos de todas las variables, tanto para el ICRU como para el ICRU 2023, se recoge en las Tablas 13 a 21 del Anexo.

Indicador	Peso
GEN1	0,461
GEN2	0,252
GEN3	0,287

Tabla 4. Pesos de la dimensión de generación (ICRU).

Indicador	Peso
GOB1	0,492
GOB2	0,006
GOB3	0,502

Tabla 5. Pesos de la dimensión de gobernanza (ICRU).

El reparto de pesos refleja el comportamiento estadístico de cada dimensión. En generación, GEN1 (residuos per cápita) concentra el mayor peso (0,46), por delante de GEN3 y GEN2, lo que señala la cantidad total de residuos como la variable que mejor sintetiza la presión inicial sobre el sistema. En tratamiento (Tabla 11), los pesos se reparten de forma equilibrada entre los cinco indicadores (entre 0,11 y 0,27), reflejo de la elevada

coherencia interna de esta dimensión, donde las distintas vías de tratamiento tienden a avanzar de forma conjunta.

En gobernanza, GOB1 y GOB3 acaparan prácticamente todo el peso, mientras que GOB2 queda reducido a un valor casi nulo (0,006). Este resultado es directamente atribuible a la baja adecuación muestral de GOB2 detectada en el test KMO y a su escasa correlación con el resto de la dimensión: al apenas contribuir al primer componente, su carga al cuadrado es mínima. La metodología, por tanto, penaliza automáticamente a los indicadores poco integrados en la estructura común. En impacto medioambiental (Tabla 13) se reproduce el mismo patrón: IMP1 e IMP2 acaparan el peso e IMP3 (incineración sin recuperación) queda en 0,04, en coherencia con su baja adecuación en el KMO y su comportamiento independiente del resto.

En conjunto, el método de ponderación se comporta de la forma esperada: reparte el peso de manera equilibrada en las dimensiones internamente cohesionadas y lo concentra en los indicadores más representativos allí donde alguna variable aporta información independiente o ruidosa. Este resultado refuerza la coherencia entre el comportamiento estadístico de los datos y la estructura conceptual del índice.

3.6 Agregación

La agregación del ICRU se realiza en dos niveles. En el primero, los indicadores normalizados, orientados y ponderados de cada dimensión se combinan en una puntuación de dimensión mediante una suma ponderada:

$$D_k = \sum_{i \in k} w_i v_i$$

Fórmula 8. Agregación de los indicadores en cada dimensión.

En el segundo nivel, las puntuaciones de las K dimensiones se combinan en el índice final mediante una media aritmética:

$$ICRU = \frac{1}{K} \sum_{k=1}^{K} D_k$$

Fórmula 9. Agregación final del ICRU (media aritmética de las dimensiones).

Se ha elegido la media aritmética por ser el método de agregación más extendido y transparente, y porque permite la compensación entre dimensiones: un buen desempeño en una de ellas puede contrarrestar un peor resultado en otra (Gan et al., 2017). Esta propiedad, razonable en el contexto del ICRU, se somete no obstante a prueba en el capítulo siguiente,

donde se compara la agregación aritmética con una alternativa geométrica que limita dicha compensación.

4. Resultados, robustez y validación

Una vez construido el ICRU, este capítulo presenta sus principales resultados, evalúa su robustez frente a decisiones metodológicas alternativas y lo contrasta con una referencia externa. Salvo indicación contraria, los análisis se apoyan en el panel de 2014 a 2023 y se complementan con el corte transversal de 2023.

4.1 Resultados

La aplicación del ICRU proporciona una puntuación de circularidad, comprendida entre 1 y 100, para cada país y año del panel, así como para el corte transversal de 2023. Las puntuaciones más altas corresponden a países con sistemas de gestión de residuos consolidados, caracterizados por elevadas tasas de reciclaje y recuperación y por un escaso recurso al vertido; las más bajas, a países que todavía dependen en gran medida del vertido y presentan una menor capacidad operativa e institucional.

El análisis se inicia con una visión transversal del ICRU en su versión correspondiente al año 2023, que ofrece la fotografía más reciente y completa del estado de la circularidad en Europa. La Figura 5 representa la distribución geográfica del índice, donde una gradación cromática del rojo al verde refleja un menor o mayor grado de circularidad, y la Tabla 6 recoge el ranking completo con sus valores.

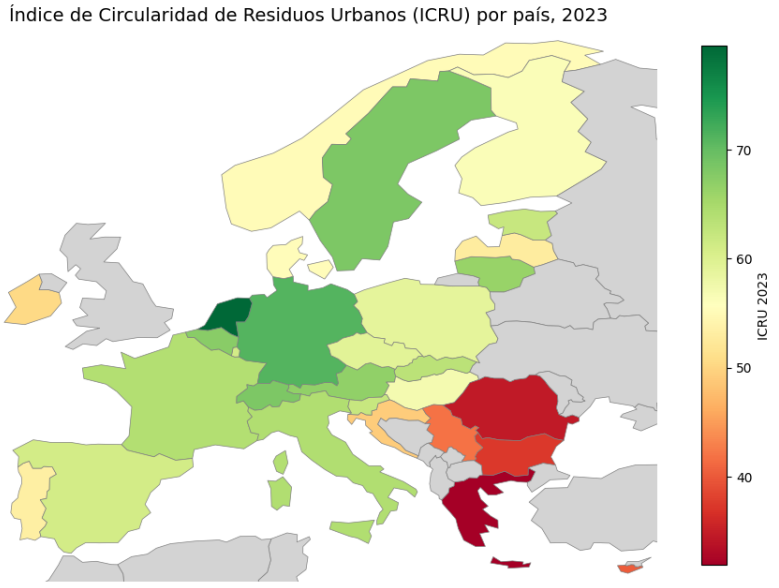


Figura 5. Mapa de calor ICRU 2023.

Ranking del ICRU 2023

#	País	ICRU 2023
1	Netherlands	79.5
2	Germany	71.1
3	Switzerland	68.4
4	Sweden	68.3
5	Belgium	67.4
6	Austria	66.8
7	Lithuania	66.2
8	Italy	64.2
9	France	64.1
10	Slovakia	63.2
11	Slovenia	62.2
12	Estonia	62.1
13	Luxembourg	61.1
14	Spain	61.1
15	Czechia	59.3
16	Poland	59.0
17	Hungary	57.1
18	Finland	56.3
19	Denmark	55.3
20	Norway	55.1
21	Portugal	53.3
22	Latvia	52.7
23	Iceland	51.6
24	Ireland	50.5
25	Türkiye	50.2
26	Croatia	49.2
27	Malta	43.4
28	Serbia	41.8
29	Cyprus	40.2
30	Bulgaria	37.4
31	Romania	34.7
32	Greece	31.9

Tabla 6. Ranking ICRU 2023.

Tanto el mapa como el ranking revelan un marcado patrón geográfico. Los niveles más elevados de circularidad se concentran en el centro y el norte de Europa, encabezados por los Países Bajos, que alcanzan la puntuación más alta del conjunto (79,5), seguidos de Alemania (71,1), Suiza (68,4), Suecia (68,3) y Bélgica (67,4). En el extremo opuesto se sitúan los países del sureste europeo, con Grecia como el de menor desempeño (31,9), precedida de Rumanía (34,7), Bulgaria (37,4) y Chipre (40,2). El ICRU medio del conjunto se sitúa en torno a 56 puntos, y la brecha de casi 48 puntos entre el primer y el último país pone de manifiesto la notable heterogeneidad que persiste en el grado de adopción de prácticas circulares dentro de Europa, pese a compartir un mismo marco normativo comunitario.

La descomposición del índice por dimensiones (Tabla 7) permite entender qué hay detrás de estas diferencias. El factor que más nítidamente separa a los países líderes de los rezagados es el tratamiento: mientras que los primeros superan holgadamente los 70 puntos en esta dimensión (72,7 los Países Bajos, 73,6 Bélgica, 71,2 Suiza), los situados en la cola se desploman hasta valores en torno a 15-23 puntos (14,9 Serbia, 9,3 Rumanía, 22,5 Grecia). Es precisamente la capacidad de reciclar, compostar y recuperar materiales, frente a la mera eliminación, lo que marca la distancia en el desempeño global.

Puntuación por dimensión: países líderes y rezagados (ICRU 2023)

País	Generación	Tratamiento	Infraest.	Gobernanza	Impacto	ICRU
Netherlands	78.6	72.7	88.0	64.1	94.3	**79.5**
Germany	45.6	70.0	67.0	73.9	99.1	**71.1**
Switzerland	43.5	71.2	71.2	69.2	86.7	**68.4**
Sweden	84.6	59.9	64.6	32.5	99.6	**68.3**
Belgium	25.9	73.6	70.5	67.0	100.0	**67.4**
Serbia	46.1	14.9	63.0	70.3	14.9	**41.8**
Cyprus	30.7	14.9	47.8	64.3	43.5	**40.2**
Bulgaria	53.2	23.2	9.0	58.6	42.8	**37.4**
Romania	74.2	9.3	7.3	50.6	32.0	**34.7**
Greece	51.1	22.5	7.8	74.6	3.5	**31.9**

Tabla 7. Puntiación por dimensión de top 5 y bottom 5, ICRU 2023.

El resto de dimensiones, en cambio, ofrece un panorama más matizado y no siempre alineado con la posición final. La generación de residuos no discrimina con claridad entre buenos y malos: países rezagados como Rumanía (74,2) o Bulgaria (53,2) obtienen en esta dimensión puntuaciones similares o incluso superiores a las de algunos líderes como Alemania (45,6) o Suiza (43,5). Algo parecido ocurre con la gobernanza, donde Grecia (74,6) puntúa por encima de varios países de cabeza. Esto revela que un buen resultado en una dimensión aislada no basta para alcanzar una circularidad elevada: son los países capaces de combinar un desempeño sólido en varias dimensiones, y muy especialmente en tratamiento, los que encabezan el índice. El caso de Grecia es ilustrativo: pese a una gobernanza notable, su mínimo desempeño en tratamiento (22,5) e impacto (3,5) la relega al último puesto.

Este patrón es coherente con la estructura identificada en el análisis multivariante, donde la dimensión de tratamiento se reveló como el núcleo estadístico de la circularidad, y refuerza la idea de que las diferencias entre países responden fundamentalmente a la capacidad operativa de sus sistemas de gestión de residuos.

La evolución del ordenamiento de los países a lo largo del periodo se recoge en la Figura 6. El ranking se mantiene relativamente estable, con movimientos graduales antes que reordenamientos bruscos, lo que resulta coherente con el carácter estructural de los sistemas de gestión de residuos, que evolucionan de forma lenta. No obstante, sí se aprecian trayectorias particulares de mejora y de retroceso a lo largo de los años.

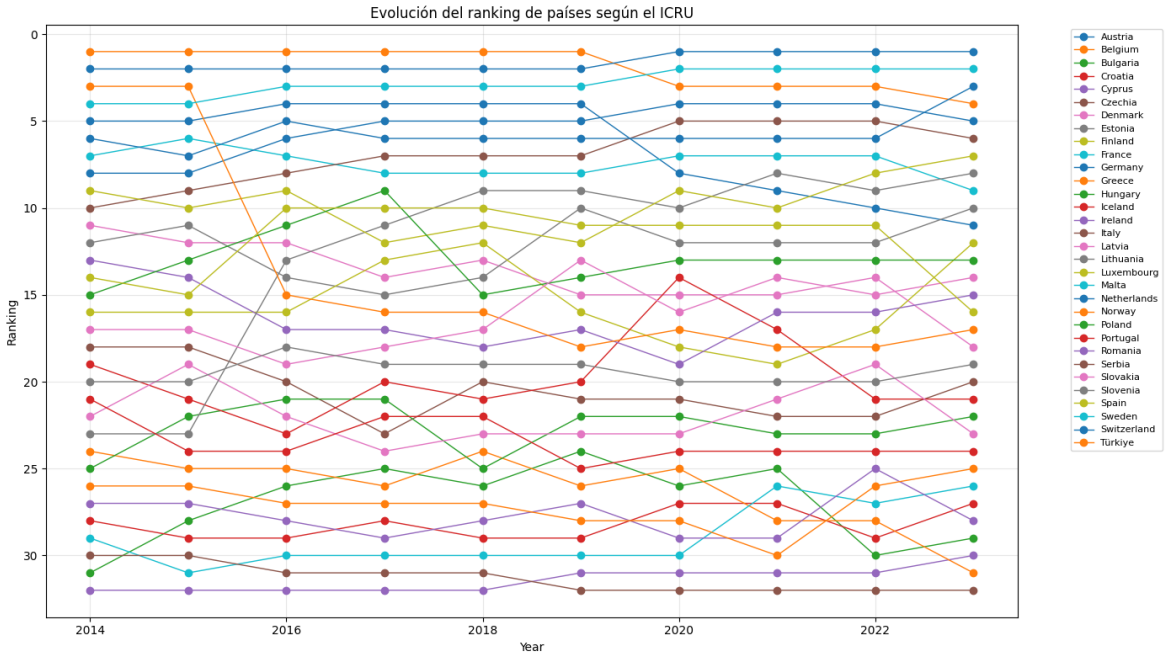


Figura 6. Evolución del ranking de países según el ICRU (2014-2023).

Para ilustrar estas trayectorias, la Figura 7 representa la evolución por dimensiones de tres países con perfiles diferenciados: Islandia, Chequia y Turquía. La comparación entre Islandia y Chequia muestra que su evolución relativa no se explica por una única dimensión, sino por la interacción de varias. Islandia mantiene durante la mayor parte del periodo un nivel de ICRU superior, sustentado en una mejora pronunciada y sostenida de la dimensión de gobernanza, que compensa el deterioro observado en la dimensión de generación. Chequia, partiendo de un nivel próximo al de Islandia, evoluciona con menor pendiente hasta 2022 y experimenta en 2023 un avance marcado, principalmente en gobernanza, que la sitúa al nivel de Islandia al final del periodo. Turquía, por su parte, presenta un perfil claramente diferenciado, con niveles reducidos de tratamiento y gobernanza pero con una dimensión de generación elevada; su bajo valor de ICRU no se explica, por tanto, por la presión ambiental, sino por la capacidad operativa e institucional de su sistema de residuos.

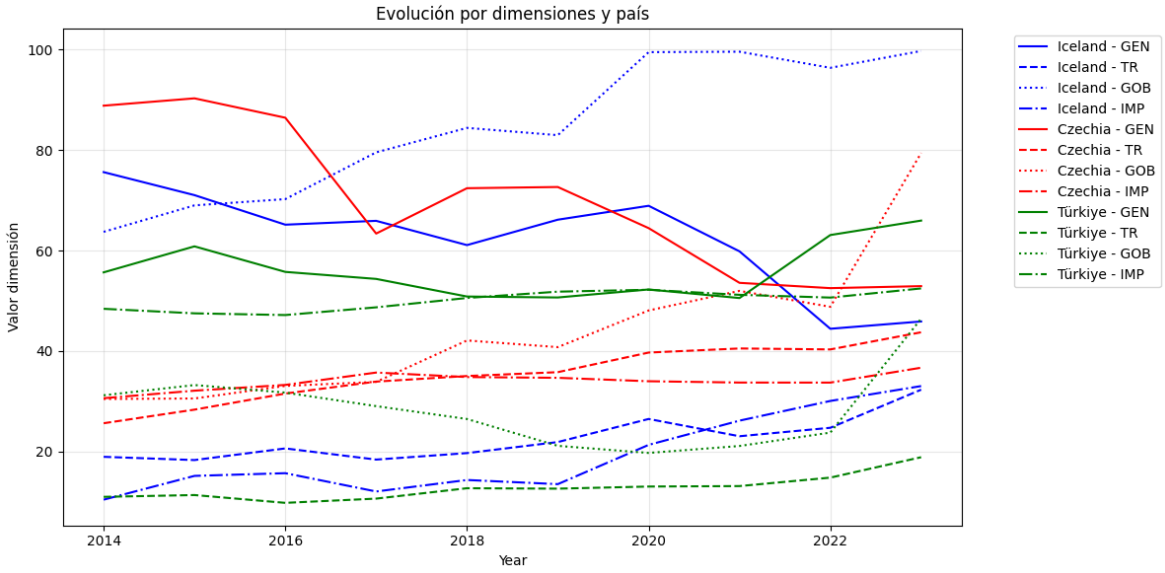


Figura 7. Evolución por dimensiones de tres países representativos (Islandia, Chequia y Turquía).

4.2 Análisis de robustez

La construcción de un indicador compuesto implica una serie de decisiones metodológicas, especialmente en las etapas de ponderación y agregación, que introducen cierto grado de discrecionalidad. El análisis de robustez tiene por objeto comprobar en qué medida los resultados del ICRU dependen de estas decisiones. Para ello se han contrastado dos especificaciones alternativas frente al indicador principal.

En primer lugar, se ha sustituido la ponderación basada en componentes principales por una ponderación igualitaria, en la que todos los indicadores de cada dimensión reciben el mismo peso. Las siguientes figuras comparan ambas especificaciones tanto en el panel como en el corte de 2023. La correlación entre el indicador principal y esta alternativa es muy elevada, de 0,960 en el panel completo y de 0,965 en el corte transversal de 2023.

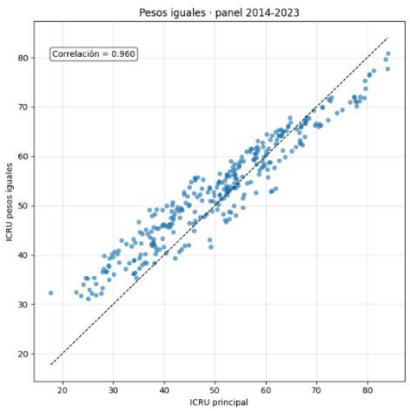


Figura 8. Comparación entre el ICRU principal y la especificación con ponderación igualitaria.

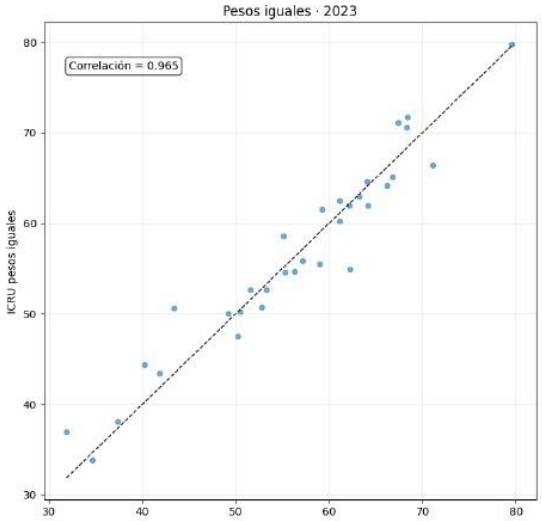


Figura 9. Comparación entre el ICRU principal y la especificación con ponderación igualitaria (2023).

En segundo lugar, se ha sustituido la media aritmética entre dimensiones por una media geométrica, que limita la compensación entre ellas y penaliza en mayor medida los desempeños desiguales. La Figura 10 recoge esta comparación para el panel. También en este caso la correlación con el indicador principal es muy alta, de 0,983 en el panel y de 0,987 en el corte de 2023.

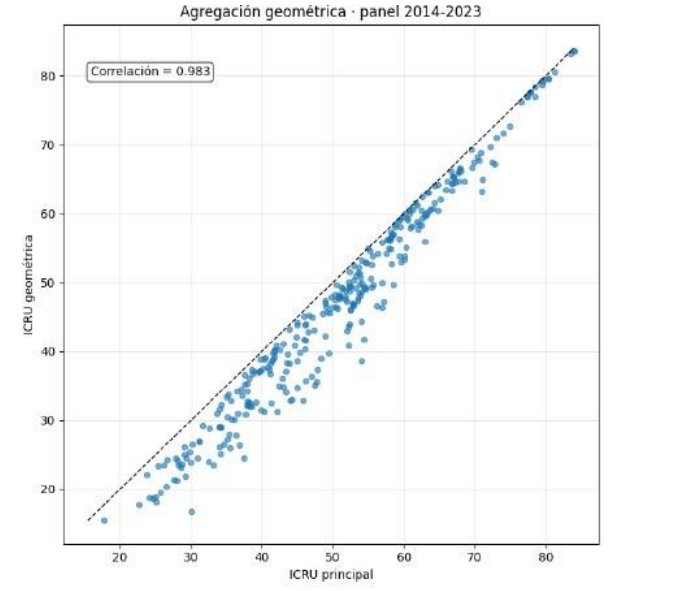


Figura 10. Comparación entre el ICRU principal y la agregación geométrica (panel 2014-2023).

En conjunto, ambas pruebas arrojan correlaciones superiores a 0,96 en todos los casos, lo que indica que el ordenamiento de los países apenas varía al modificar el esquema de ponderación o el método de agregación. El ICRU presenta, por tanto, un grado de robustez elevado, lo que refuerza la validez de la especificación principal.

Para complementar el análisis de correlación con una medida más intuitiva, se calcula el desplazamiento medio de posiciones, que cuantifica cuántos puestos cambia de media cada país en el ranking al modificar la especificación del índice (OCDE, 2008). La Tabla 8 recoge los resultados. Las cifras son reducidas en todos los casos: al sustituir la ponderación por componentes principales por una ponderación igualitaria, cada país se desplaza de media solo 2,08 posiciones en el panel temporal y 1,44 en el corte de 2023; al cambiar la agregación aritmética por una media geométrica, el desplazamiento es aún menor (1,41 y 1,19 posiciones, respectivamente). Teniendo en cuenta que el ranking abarca 32 países, un movimiento medio de entre una y dos posiciones resulta prácticamente despreciable y confirma que la ordenación de los países es muy estable frente a decisiones metodológicas alternativas. Este resultado refuerza la conclusión anterior: ni el esquema de ponderación ni el método de agregación alteran de forma relevante los resultados, lo que avala la solidez de la especificación principal del ICRU.

Análisis de robustez del ICRU: desplazamiento medio de posiciones

Especificación alternativa	Desp. medio (panel 2014-2023)	Desp. medio (2023)
Pesos iguales (vs PCA)	2.08	1.44
Media geométrica (vs aritmética)	1.41	1.19

Tabla 8. Variación media de posiciones de ICRU e ICRU 2023.

4.3 Validación externa

Con el fin de aportar evidencia adicional sobre la validez del indicador, se ha realizado una validación externa comparando el ICRU con una referencia ajena a su construcción: el PIB per cápita. El objetivo no es afirmar una relación causal entre ambas variables, sino comprobar si el indicador presenta una asociación plausible con el grado de desarrollo económico, en línea con lo que cabría esperar.

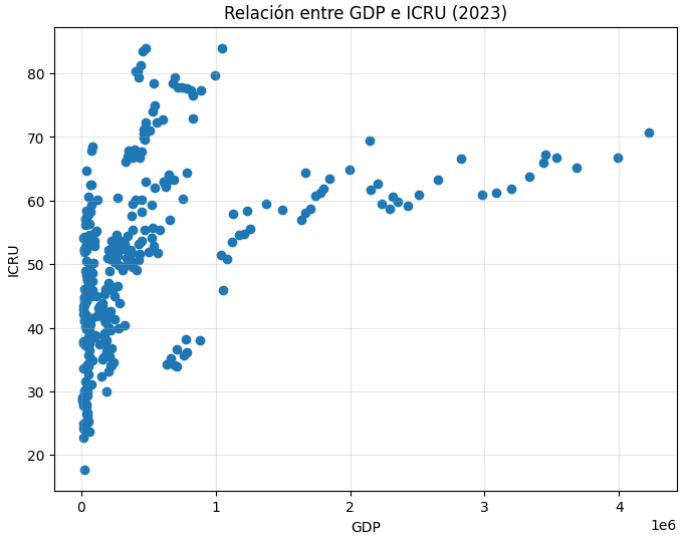


Figura 11. Comparación entre el ICRU 2023 y PIB.

El contraste muestra una asociación positiva, aunque moderada: los países con mayor capacidad económica tienden a obtener puntuaciones de ICRU más elevadas, lo que resulta razonable, ya que el desarrollo económico facilita la inversión en infraestructuras de gestión de residuos y en capacidad institucional. Ahora bien, la relación dista de ser perfecta, lo que constituye precisamente un resultado deseable: indica que el ICRU recoge información que va más allá de la mera riqueza económica. Algunos países alcanzan niveles de circularidad elevados en relación con su renta, y a la inversa, lo que confirma que el indicador mide un fenómeno propio, el desempeño en circularidad, y no un simple reflejo del PIB.

5. Conclusiones

El presente trabajo ha tenido como objetivo el diseño y la construcción de un indicador compuesto, el Indicador de Circularidad de Residuos Urbanos (ICRU), capaz de medir y comparar el desempeño en circularidad de la gestión de residuos urbanos en los países europeos. Para ello se ha seguido la secuencia metodológica habitual en la literatura sobre indicadores compuestos, articulada en torno a la construcción de una base de datos, el

tratamiento de los valores ausentes, la normalización y orientación de las variables, el análisis de su estructura, y la ponderación y agregación finales.

La principal aportación del ICRU reside en su carácter sintético y multidimensional. Frente a los indicadores parciales que habitualmente se emplean para evaluar la gestión de residuos, como la tasa de reciclaje, el ICRU integra en una única medida varias dimensiones complementarias, lo que ofrece una visión más completa del fenómeno y facilita tanto la comparación entre países como su seguimiento a lo largo del tiempo.

Los resultados obtenidos muestran un ordenamiento de los países coherente con lo esperable, con los sistemas de gestión más consolidados a la cabeza y una distribución de los países a lo largo de un continuo de desempeño, antes que en grupos nítidamente diferenciados. El análisis de robustez ha confirmado que este ordenamiento es estable frente a especificaciones alternativas de la ponderación y la agregación, con correlaciones superiores a 0,96 en todos los casos. Por su parte, la validación externa frente al PIB per cápita ha mostrado una asociación positiva pero moderada, lo que indica que el indicador capta información propia y no se limita a reflejar el nivel de renta de cada país.

No obstante, el trabajo presenta una serie de limitaciones que conviene reconocer y que, a su vez, abren vías de mejora. La primera de ellas tiene que ver con los datos. La construcción del ICRU depende por completo de la información disponible en Eurostat, cuya cobertura es desigual. En particular, las variables de infraestructura solo están disponibles de forma fiable para el año más reciente, por lo que la versión en panel del indicador prescinde de la dimensión de infraestructura, que sí se incorpora en el corte transversal de 2023. La presencia de datos ausentes obligó, además, a un tratamiento de imputación cuyo alcance conviene no sobrevalorar.

A las anteriores se suman algunas limitaciones de carácter metodológico. La ponderación basada en componentes principales asigna un peso muy reducido a los indicadores poco correlacionados con el eje principal de su dimensión, como GOB2 o IMP3, lo que puede infrarrepresentar variables conceptualmente relevantes. Por último, la adecuación muestral del corte de 2023 resultó limitada y la estructura de conglomerados, débil, por lo que los resultados de estas partes deben interpretarse con cautela.

Estas limitaciones señalan, en buena medida, las principales líneas de trabajo futuro. La más inmediata consiste en ampliar la cobertura temporal y, sobre todo, la disponibilidad de las variables de infraestructura, de modo que la dimensión correspondiente pueda incorporarse también a la versión en panel. Resultaría igualmente interesante explorar esquemas alternativos de ponderación y agregación, así como incorporar un análisis de

sensibilidad más formal que cuantifique la incertidumbre asociada a cada decisión metodológica. Finalmente, el indicador podría enriquecerse desagregando por flujos de residuos o vinculándose de forma explícita a los objetivos de las políticas europeas de economía circular, lo que reforzaría su utilidad como herramienta de seguimiento.

En definitiva, el ICRU constituye una propuesta sólida y replicable para medir la circularidad de la gestión de residuos urbanos en Europa. Pese a las limitaciones señaladas, ofrece una base metodológica consistente y transparente sobre la que es posible seguir avanzando.

6. Bibliografía

Azevedo, S. G., Godina, R., y Matias, J. C. O. (2017). Proposal of a sustainable circular index for manufacturing companies. Resources, 6(4): 63.

Circle Economy (2018). The Circularity Gap Report 2018. Circle Economy, Amsterdam. Disponible en: https://www.circularity-gap.world/2018

Circle Economy (2025). The Circularity Gap Report 2025. Circle Economy, Amsterdam. Disponible en: https://www.circularity-gap.world/2025

Comisión Europea. (2015). Cerrar el círculo: un plan de acción de la UE para la economía circular (COM(2015) 614 final). Oficina de Publicaciones de la Unión Europea.

Comisión Europea. (2018a). Informe relativo a la aplicación del Plan de Acción para la Economía Circular (COM(2018) 29 final). Oficina de Publicaciones de la Unión Europea.

Comisión Europea (2018b). Circular Economy Monitoring Framework. European Commission, Brussels.

Comisión Europea. (2019). El Pacto Verde Europeo (COM(2019) 640 final). Oficina de Publicaciones de la Unión Europea.

Comisión Europea. (2020). Un nuevo Plan de Acción para la Economía Circular: Por una Europa más limpia y más competitiva (COM(2020) 98 final). Oficina de Publicaciones de la Unión Europea.

Di Maio, F., y Rem, P. C. (2015). A robust indicator for promoting circular economy through recycling. Journal of Environmental Protection, 6: 1095–1104.

Ellen MacArthur Foundation. (2015). *Circularity indicators: An approach to measuring circularity – Methodology*. Ellen MacArthur Foundation.

Eurostat. (s. f.). Circular economy – Monitoring framework [base de datos]. Eurostat. Disponible en: https://ec.europa.eu/eurostat/web/circular-economy

Fernández de Gatta Sánchez, D. (2020): “El ambicioso Pacto Verde Europeo”. Actualidad Jurídica Ambiental (101): 81.

Freudenberg, M. (2003) Composite Indicators of Country Performance: A Critical Assessment. OECD Science Technology and Industry Working Papers No. 16, OECD Publishing, Paris.

García Lupiola, A. (2022). El Pacto Verde Europeo y las propuestas para su desarrollo. ¿Mayor ambición de la UE para alcanzar el desarrollo sostenible? Revista de Estudios Europeos, 79: 80–114.

Garrido, A., González, M., Morales, J., y Martín, J. M. (2023). A composite circular economy index for assessing circular practices at the organisational level. Journal of Environmental Management, 335: 117540.

Greco, S., Ishizaka, A., Tasiou, M., y Torrisi, G. (2019). On the Methodological Framework of Composite Indices: A Review of the Issues of Weighting, Aggregation, and Robustness. Social Indicators Research, 141(1): 61–94.

Lovell, C. A. K., Pastor, J. T., y Turner, J. A. (1995). Measuring macroeconomic performance in the OECD: A comparison of European and non-European countries. European Journal of Operational Research, 87(3): 507–518.

Nardo, M., Saisana, M., Saltelli, A., y Tarantola, S. (2005). Tools for Composite Indicators Building. Joint Research Centre.

OCDE (2008). Handbook on Constructing Composite Indicators: Methodology and User Guide. Disponible en: https://www.oecd.org/sdd/42495745.pdf

REtema. (s. f.). La UE publica una infografía con datos y cifras sobre la gestión de residuos en la UE. https://www.retema.es/actualidad/la-ue-publica-una-infografia-con-datos-y-cifras-sobre-la-gestion-de-residuos-en-el

Unión Europea. (1994). Directiva 94/62/CE del Parlamento Europeo y del Consejo, de 20 de diciembre de 1994, relativa a los envases y residuos de envases. Diario Oficial de las Comunidades Europeas, L 365, 10–23.

Unión Europea. (2006). Directiva 2006/66/CE del Parlamento Europeo y del Consejo, de 6 de septiembre de 2006, relativa a las pilas y acumuladores y a los residuos de pilas y acumuladores y por la que se deroga la Directiva 91/157/CEE. Diario Oficial de la Unión Europea, L 266, 1–14.

Unión Europea. (2008). Directiva 2008/98/CE del Parlamento Europeo y del Consejo, de 19 de noviembre de 2008, sobre los residuos y por la que se derogan determinadas Directivas. Diario Oficial de la Unión Europea, L 312, 3–30.

Unión Europea. (2012). Directiva 2012/19/UE del Parlamento Europeo y del Consejo, de 4 de julio de 2012, sobre residuos de aparatos eléctricos y electrónicos (RAEE). Diario Oficial de la Unión Europea, L 197, 38–71.

van Buren, N., Demmers, M., van der Heijden, R., y Witlox, F. (2016). Towards a circular economy: The role of Dutch logistics industries and governments. Sustainability, 8: 647. https://doi.org/10.3390/su8070647

7. Anexos

7.1 Código fuente

El indicador se ha implementado fundamentalmente en Python, encargado de la construcción de la base de datos, el tratamiento de los valores ausentes, la normalización, la ponderación y la agregación, y en R, empleado para el análisis multivariante.

7.1.1 Código Python

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import sys
import os
from functools import reduce
import warnings
import missingno as msno
from scipy import stats
import statsmodels.api as sm
import seaborn as sns
from scipy.stats import chi2
from sklearn.decomposition import PCA
from sklearn.metrics import mean_squared_error, mean_absolute_error
from sklearn.linear_model import LinearRegression
from sklearn.experimental import enable_iterative_imputer
from sklearn.impute import IterativeImputer
from scipy.linalg import cho_factor, cho_solve
from scipy.optimize import linprog
from statsmodels.tsa.holtwinters import ExponentialSmoothing
warnings.filterwarnings("ignore")
def clean_number_series(s):
    s = s.astype(str).str.strip()

    # Convertir símbolos vacíos o ":" en NaN
    s = s.replace([":", "NaN", "nan", " ", "", ".", "..", "..."],
np.nan)

    # --- asegurar que las máscaras no contengan NaN ---
    mask_thousand = s.str.contains(r'\d+\.\d+,\d+',
regex=True).fillna(False)
    mask_comma = s.str.contains(',', regex=True).fillna(False) &
~mask_thousand

    # Si hay comas y puntos (1.234,56) → quitar puntos y cambiar coma
por punto
    s.loc[mask_thousand] = (
```

```
        s[mask_thousand]
        .str.replace('.', '', regex=False)
        .str.replace(',', '.', regex=False)
    )

    # Si solo hay comas (565,00) → cambiar coma por punto
    s.loc[mask_comma] = s[mask_comma].str.replace(',', '.',
regex=False)

    # Quitar espacios finos y convertir a float
    s = s.str.replace('\u00A0', '', regex=False)
    return pd.to_numeric(s, errors='coerce')
def mardia_test(df, min_n, verbose):
    # 1) tomar solo filas completas
    X = df.dropna(axis=0, how="any").to_numpy(dtype=float)
    n, p = X.shape

    # 2) centrar y covarianza
    mu = X.mean(axis=0) # --> es el centro
    Xc = X - mu # --> datos centrados
    S  = np.cov(Xc, rowvar=False, bias=True) # --> covarianza
muestral
    S_inv = np.linalg.pinv(S)  # --> inversa de matriz de covarianzas
    D2 = np.einsum('ij,jk,ik->i', Xc, S_inv, Xc) # --> distancias de
Mahlanois

    # Asimetría
    B = Xc @ S_inv @ Xc.T
    b1p = (B**3).sum() / (n**2)

    # Estadístico ~ chi2_{p(p+1)(p+2)/6}
    chi2_skew = n * b1p / 6.0
    df_skew   = p * (p + 1) * (p + 2) // 6
    p_skew    = stats.chi2.sf(chi2_skew, df_skew)

    # Curtosis (kurtosis)
    b2p = np.mean(D2**2)
    Eb2   = p * (p + 2)
    Varb2 = (8.0 * p * (p + 2)) / n
    z_kurt = (b2p - Eb2) / np.sqrt(Varb2)
    p_kurt = 2.0 * stats.norm.sf(abs(z_kurt))

    if verbose:
        print("Test de Mardia (normalidad multivariante)")
        print(f"  n = {n}, p = {p}")
        print(f"  Asimetría:  b1p = {b1p:.6f} | Chi² =
{chi2_skew:.3f} | gl = {df_skew} | p = {p_skew:.4g}")
        print(f"  Curtosis:   b2p = {b2p:.6f} | z    =
{z_kurt:.3f}       | p = {p_kurt:.4g}")
```

```
        both_ok = (p_skew > 0.05) and (p_kurt > 0.05)
        print("  → " + ("No se rechaza la normalidad multivariante."
if both_ok
                        else "Se observan desviaciones de normalidad
(asimetría o curtosis)."))

    return {
        "n": n, "p": p,
        "b1p": b1p, "chi2_skew": chi2_skew, "df_skew": df_skew,
"p_skew": p_skew,
        "b2p": b2p, "z_kurt": z_kurt, "p_kurt": p_kurt
    }
def em_mvnorm(df, eps, max_iter, verbose):

    X = df.to_numpy(float)
    n, p = X.shape

    mu = np.nanmean(X, axis=0)
    X_complete = X[~np.isnan(X).any(axis=1)]
    if X_complete.shape[0] > 1:
        Sigma = np.cov(X_complete.T, bias=True)
    else:
        X_filled = np.where(np.isnan(X), mu, X)
        Sigma = np.cov(X_filled.T, bias=True)

    for it in range(max_iter):
        mu_prev, Sigma_prev = mu.copy(), Sigma.copy()
        S1 = np.zeros(p)
        S2 = np.zeros((p, p))

        for i in range(n):
            obs = ~np.isnan(X[i])
            mis = np.isnan(X[i])
            if np.all(mis):
                continue

            x_o = X[i, obs]
            mu_o = mu[obs]
            x_hat = mu.copy()

            if np.any(mis):
                mu_m = mu[mis]
                Sigma_mo = Sigma[np.ix_(mis, obs)]
                Sigma_oo = Sigma[np.ix_(obs, obs)]
                Sigma_mm = Sigma[np.ix_(mis, mis)]
                Sigma_oo_inv = np.linalg.pinv(Sigma_oo)

                Ex_m = mu_m + Sigma_mo @ Sigma_oo_inv @ (x_o - mu_o)
                V_m = Sigma_mm - Sigma_mo @ Sigma_oo_inv @ Sigma_mo.T
```

```
                x_hat[obs] = x_o
                x_hat[mis] = Ex_m
                EXXT = np.outer(x_hat, x_hat)
                EXXT[np.ix_(mis, mis)] += V_m
            else:
                x_hat[obs] = x_o
                EXXT = np.outer(x_hat, x_hat)

            S1 += x_hat
            S2 += EXXT

        mu = S1 / n
        Sigma = S2 / n - np.outer(mu, mu)
        Sigma = (Sigma + Sigma.T) / 2

        delta_mu = np.linalg.norm(mu - mu_prev) /
(np.linalg.norm(mu_prev) + 1e-8)
        delta_Sigma = np.linalg.norm(Sigma - Sigma_prev) /
(np.linalg.norm(Sigma_prev) + 1e-8)
        if verbose and it % 10 == 0:
            print(f"Iter {it:3d}: Δμ={delta_mu:.4f},
ΔΣ={delta_Sigma:.4f}")
        if delta_mu < eps and delta_Sigma < eps:
            print(f"Convergencia alcanzada en {it+1} iteraciones.")
            break
    else:
        print(f"No convergió tras {max_iter} iteraciones.")

    return mu, Sigma
def little_test(df, mu, Sigma):
    mask = df.isna()
    patterns = mask.drop_duplicates().reset_index(drop=True)
    chi2_total, df_total = 0, 0

    for i in range(len(patterns)):
        pattern_mask = (mask == patterns.loc[i]).all(axis=1)
        subset = df[pattern_mask]
        obs_vars = subset.columns[~patterns.loc[i]]

        if len(obs_vars) == 0:
            continue

        n_g = subset.shape[0]
        mean_g = subset[obs_vars].mean(skipna=True).to_numpy()
        mu_g = mu[[df.columns.get_loc(c) for c in obs_vars]]
        Sigma_oo = Sigma[np.ix_([df.columns.get_loc(c) for c in
obs_vars],
```

```
                                [df.columns.get_loc(c) for c in
obs_vars])]

        try:
            inv_Sigma_oo = np.linalg.pinv(Sigma_oo)
            delta = mean_g - mu_g
            chi2_g = n_g * (delta @ inv_Sigma_oo @ delta.T)
            chi2_total += chi2_g
            df_total += len(obs_vars)
        except np.linalg.LinAlgError:
            continue

    p_value = 1 - stats.chi2.cdf(chi2_total, df_total)

    print("Test de Little (MCAR)")
    print(f"Chi² = {chi2_total:.2f}, gl = {df_total}, p-valor =
{p_value:.4f}")
    if p_value > 0.05:
        print("No se rechaza MCAR → los datos pueden considerarse
aleatorios.")
    else:
        print("Se rechaza MCAR → los faltantes no son completamente
aleatorios.")

def em_impute(df, eps=1e-4, max_iter=500, verbose=False):
    """
    Usa tu em_mvnorm para estimar mu y Sigma
    y luego imputa los NA con la esperanza condicional.
    Devuelve un DataFrame sin NA.
    """
    # 1) Estimar parámetros con tu EM
    mu, Sigma = em_mvnorm(df, eps=eps, max_iter=max_iter,
verbose=verbose)

    X = df.to_numpy(float)
    n, p = X.shape
    isnan = np.isnan(X)

    X_filled = X.copy()

    for i in range(n):
        mis = isnan[i]
        obs = ~mis

        # Si toda la fila es NA, rellenamos con mu
        if np.all(mis):
            X_filled[i, :] = mu
            continue
```

```
        x_o = X[i, obs]
        mu_o = mu[obs]

        # Si no hay NA en la fila, no tocamos
        if not np.any(mis):
            continue

        mu_m = mu[mis]
        Sigma_mo = Sigma[np.ix_(mis, obs)]
        Sigma_oo = Sigma[np.ix_(obs, obs)]
        Sigma_oo_inv = np.linalg.pinv(Sigma_oo)

        # Esperanza condicional de los missing dado lo observado
        Ex_m = mu_m + Sigma_mo @ Sigma_oo_inv @ (x_o - mu_o)

        # Rellenamos los NA con esa esperanza
        X_filled[i, mis] = Ex_m

    return pd.DataFrame(X_filled, columns=df.columns)
def mlr_impute(df):
    df_imp = df.copy()

    # Medias de columnas (para rellenar predictors temporalmente)
    col_means = df_imp.mean(skipna=True)

    for col in df_imp.columns:
        mask_mis = df_imp[col].isna()
        mask_obs = ~mask_mis

        if mask_mis.sum() == 0:
            continue

        predictors = [c for c in df_imp.columns if c != col]

        # ----------- ESTE ES EL PASO IMPORTANTE -----------
        # Creamos un DF auxiliar para rellenar NaNs en PREDICTORES
        df_pred = df_imp.copy()
        df_pred[predictors] =
df_pred[predictors].fillna(col_means[predictors])
        # --------------------------------------------------

        X_obs = df_pred.loc[mask_obs, predictors].values
        y_obs = df_imp.loc[mask_obs, col].values

        X_mis = df_pred.loc[mask_mis, predictors].values

        model = LinearRegression()
        model.fit(X_obs, y_obs)
```

```
            y_pred = model.predict(X_mis)
            df_imp.loc[mask_mis, col] = y_pred

    return df_imp

path = "/content/Inputs"

files = [f for f in os.listdir(path) if f.startswith("df") and
f.endswith(".xlsx")]

for file in files:
    df_name = file.replace(".xlsx", "")
    var_name = file.replace("df", "").replace(".xlsx", "")
    df = pd.read_excel(os.path.join(path, file))
    df_long = df.melt(id_vars=['GEO'], var_name='Year',
value_name=var_name)
    df_long['Year'] = df_long['Year'].astype(int)
    globals()[df_name] = df_long
    print(f"{df_name} creado con variable '{var_name}' —
{df_long.shape[0]} registros")
sorted(df_panel['GEO'].unique())
sorted(df_panel['Year'].unique())
geos_drop = [
    'Albania',
    'Andorra',
    'Armenia',
    'Georgia',
    'Azerbaijan',
    'Belarus',
    'North Macedonia',
    'Bosnia and Herzegovina',
    'European Economic Area (EU27 - 2007-2013 and IS, LI, NO)',
    'European Economic Area (EU28 - 2013-2020 and IS, LI, NO)',
    'European Free Trade Association',
    'European Union - 27 countries (from 2020)',
    'European Union - 28 countries (2013-2020)',
    'Germany including former GDR',
    'Korea',
    'Kosovo*',
    'Liechtenstein',
    'Metropolitan France',
    'Moldova',
    'Monaco',
    'Montenegro',
    'Northern Ireland (UK) (NUTS 2021)',
    'San Marino',
    'Slovak Republic',
    'Ukraine',
    'United Kingdom',
```

```
    'Russia'
]

df_panel =
df_panel[~df_panel['GEO'].isin(geos_drop)].reset_index(drop=True)

years_drop = [2010, 2011, 2012, 2013, 202]

df_panel =
df_panel[~df_panel['Year'].isin(years_drop)].reset_index(drop=True)

print("Dimensiones:", df_panel.shape)

# --- aplicar a todas las columnas excepto GEO y Year ---
cols_to_clean = [c for c in df_panel.columns if c not in ['GEO',
'Year']]

for c in cols_to_clean:
    df_panel[c] = clean_number_series(df_panel[c])

df_panel.to_excel("ICRU_panel_2014_2023.xlsx", index=False)

# Empezamos con GEN2, tendremos que multiplicar GEN1 por HAB y
dividirlo por GDP

df_panel['GEN2'] = (df_panel['GEN1'] * df_panel['HAB']) /
(df_panel['GDP'] * 1000)

# Sacamos GEN3, TR1, TR2 y TR3 haciendo el porcentaje sobre GEN1

df_panel['GEN3'] = (df_panel['AuxGEN3'] / df_panel['GEN1']) * 100

df_panel['TR1'] = (df_panel['AuxTR1'] / df_panel['GEN1']) * 100

df_panel['TR2'] = (df_panel['AuxTR2'] / df_panel['GEN1']) * 100

df_panel['TR3'] = (df_panel['AuxTR3'] / df_panel['GEN1']) * 100

# Sacamos INFRA1 e INFRA2 usando AuxINFRA1, HAB y Area

df_panel['INFRA1'] = (df_panel['AuxINFRA1'] / df_panel['Area']) * 100

df_panel['INFRA2'] = (df_panel['AuxINFRA1'] / df_panel['HAB']) *
100000

# Sacamos TR4, que es Importaciones per capita (AuxINFRA2_2) -
Exportaciones per capita (AuxINFRA2)

df_panel['TR5'] = df_panel['AuxINFRA2_2'] - df_panel['AuxINFRA2']
```

```
# Hacemos GOB1, que es AuxGOB1 * 1000000 (esta en M€) / HAB

df_panel['GOB1'] = (df_panel['AuxGOB1'] * 1000000) / df_panel['HAB']

# Gacemos GOB2, que es AuxGOB2 / HAB * 100000

df_panel['GOB2'] = (df_panel['AuxGOB2'] / df_panel['HAB']) * 100000

# GOB3 es en terminos porcentuales sobre el PIB

df_panel['GOB3'] = df_panel['AuxGOB3'] / df_panel['GDP']

# IMP1 es kg / capita de emisiones

df_panel['IMP1'] = (df_panel['AuxIMP1'] * 1000000) / df_panel['HAB']

# IMP2 e IMP3 son porcentajes de los Aux sobre GEN1

df_panel['IMP2'] = (df_panel['AuxIMP2'] / df_panel['GEN1']) * 100

df_panel['IMP3'] = (df_panel['AuxIMP3'] / df_panel['GEN1']) * 100

df_panel[['GEO', 'Year', 'AuxGEN3', 'GEN1', 'GEN3', 'TR1', 'TR2',
'TR3', 'TR4', 'TR5', 'INFRA1','INFRA2', 'GOB1', 'GOB2', 'GOB3',
'IMP1', 'IMP2', 'IMP3']].head()
deps = {
    "GEN2":  ["GEN1", "HAB", "GDP"],
    "GEN3":  ["AuxGEN3", "GEN1"],
    "TR1":   ["AuxTR1", "GEN1"],
    "TR2":   ["AuxTR2", "GEN1"],
    "TR3":   ["AuxTR3", "GEN1"],
    "INFRA1":["AuxINFRA1", "Area"],
    "INFRA2":["AuxINFRA1", "HAB"],
    "TR5":["AuxINFRA2_2", "AuxINFRA2"],
    "GOB1":  ["AuxGOB1", "HAB"],
    "GOB2":  ["AuxGOB2", "HAB"],
    "GOB3":  ["AuxGOB3", "GDP"],
    "IMP1":  ["AuxIMP1", "HAB"],
    "IMP2":  ["AuxIMP2", "GEN1"],
    "IMP3":  ["AuxIMP3", "GEN1"],
}

for target, sources in deps.items():
    mask_nan = df_panel[sources].isna().any(axis=1)
    df_panel.loc[mask_nan, target] = np.nan
df_panel.loc[df_panel["Year"] == 2023,
["AuxGOB1","AuxGOB2","AuxGOB3"]].isna().sum()
df1 = df_panel
```

```
print(list(df1.columns))
cols_final = [
    'GEO', 'Year',
    # 1. Generación
    'GEN1', 'GEN2', 'GEN3',
    # 2. Tratamiento
    'TR1', 'TR2', 'TR3', 'TR4', 'TR5',
    # 3. Infraestructura
    'INFRA1', 'INFRA2',
    # 4. Gobernanza
    'GOB1', 'GOB2', 'GOB3',
    # 5. Impacto medioambiental
    'IMP1', 'IMP2', 'IMP3'
]

df1 = df1[cols_final].copy()

df1['Year'] = df1['Year'].astype(int)
df1['GEO'] = df1['GEO'].astype(str).str.strip()

df1.head()
df1.to_excel("df1.xlsx", index=False)
df = df1.copy()
aux_cols = ['Area', 'HAB', 'GDP']

df = df.merge(
    df_panel[['GEO', 'Year'] + aux_cols],
    on=['GEO', 'Year'],
    how='left'
)
vars_num = [c for c in df.columns if c not in ['GEO', 'Year']]
missing_year_var = (
    df.groupby('Year')[vars_num]
    .apply(lambda x: x.isna().mean())
    .T
)

huecos_completos = (missing_year_var == 1.0)
vars_con_huecos = huecos_completos[huecos_completos.any(axis=1)]

print("Variables con algún año totalmente vacío:")
display(vars_con_huecos)
last_year = 2023

for var in ['GEN3', 'GOB1']:
    for geo, sub in df.groupby('GEO'):
        s = sub.sort_values('Year').set_index('Year')[var]

        if (last_year in s.index) and pd.isna(s.loc[last_year]):
```

```
            y = s.dropna()

            if len(y) >= 3:
                try:
                    model = ExponentialSmoothing(y, trend="add",
seasonal=None).fit()
                    fcast = model.forecast(1).iloc[0]
                    df.loc[(df['GEO'] == geo) & (df['Year'] ==
last_year), var] = fcast
                except Exception:
                    pass
missing_year_var = (
    df.groupby('Year')[vars_num]
    .apply(lambda x: x.isna().mean())
    .T
)

huecos_completos = (missing_year_var == 1.0)
vars_con_huecos = huecos_completos[huecos_completos.any(axis=1)]

print("Variables con algún año totalmente vacío:")
display(vars_con_huecos)
df_test = df.drop(columns=['Year', 'GEO', 'INFRA1', 'INFRA2'])
mu, Sigma = em_mvnorm(df_test, 1e-6, 200, True)
df_miss = df.copy()

for col in df_miss.columns:
    if df_miss[col].isna().sum() > 0:
        df_miss[f"miss_{col}"] = df_miss[col].isna().astype(int)
df_miss = df_miss.select_dtypes(include="number")
# Matriz de correlaciones completa
corr = df_miss.corr()

# Filtrar para ver solo correlaciones con indicadores de ausencia
corr_missing = corr.filter(like="miss_")
plt.figure(figsize=(12,8))
sns.heatmap(
    corr_missing,
    annot=True,       # mostrar números
    fmt=".1f",        # un decimal
    cmap="coolwarm",  # paleta de colores
    vmin=-1, vmax=1   # escala simétrica (opcional)
)
plt.title("Correlaciones entre variables observadas y patrones de
ausencia")
plt.tight_layout()
plt.show()
df.columns.tolist()
df_aux = df.drop(columns=["Year", "GEO", "INFRA1", "INFRA2"])
```

```
lower = df_aux.quantile(0.05)
upper = df_aux.quantile(0.95)
df_clipped = df_aux.clip(lower=lower, upper=upper, axis=1)
df_mm = 1 + 99 * (df_clipped - df_clipped.min()) / (df_clipped.max()
- df_clipped.min())

infra_aux = df[["INFRA1", "INFRA2"]]

lower_i = infra_aux.quantile(0.05)
upper_i = infra_aux.quantile(0.95)
infra_clipped = infra_aux.clip(lower=lower_i, upper=upper_i, axis=1)
infra_mm = 1 + 99 * (infra_clipped - infra_clipped.min()) /
(infra_clipped.max() - infra_clipped.min())
df_mm = pd.concat(
    [df[["Year"]], df_mm],
    axis=1
)
year_dummies = pd.get_dummies(df_mm["Year"], prefix="Y",
drop_first=True)
df_mm = pd.concat(
    [df_mm.drop(columns=["Year"]), year_dummies],
    axis=1
)
df_complete = df_mm.dropna().copy()
df_complete.describe()
exclude_cols = list(year_dummies.columns)
df_sim_missing, miss_mask = make_missing(df_complete, frac=0.1,
random_state=42, exclude_cols=exclude_cols)

df_EM   = df_sim_missing.copy()
df_MLR  = df_sim_missing.copy()
df_MICE = df_sim_missing.copy()
print("NaNs totales en df_sim_missing:",
df_sim_missing.isna().sum().sum())
print("Celdas marcadas como missing en miss_mask:", miss_mask.sum())
imp_EM = em_impute(df_EM, eps=1e-4, max_iter=500, verbose=True)
rmse_EM, mae_EM, nrmse_EM = compute_metrics(df_complete, imp_EM,
miss_mask)

print("Errores método EM:")
print("RMSE :", rmse_EM)
print("MAE  :", mae_EM)
print("NRMSE:", nrmse_EM)
imp_MLR = mlr_impute(df_MLR)
rmse_MLR, mae_MLR, nrmse_MLR = compute_metrics(df_complete, imp_MLR,
miss_mask)

print("Errores método MLR:")
print("RMSE :", rmse_MLR)
```

```
print("MAE  :", mae_MLR)
print("NRMSE:", nrmse_MLR)
# Partimos de df_MICE = df_sim_missing.copy() que ya tienes
imputer_mice = IterativeImputer(
    random_state=42,
    max_iter=20,          # nº de iteraciones del ciclo MICE
    sample_posterior=False  # True → imputación aleatoria, False →
determinista
)

X_mice = imputer_mice.fit_transform(df_MICE)

imp_MICE = pd.DataFrame(
    X_mice,
    columns=df_MICE.columns,
    index=df_MICE.index
)
rmse_MICE, mae_MICE, nrmse_MICE = compute_metrics(df_complete,
imp_MICE, miss_mask)

print("Errores método MICE:")
print("RMSE :", rmse_MICE)
print("MAE  :", mae_MICE)
print("NRMSE:", nrmse_MICE)
df_imputed_aux = df_imputed_aux.drop(columns=exclude_cols)
df_imputed_aux = df_imputed_aux.clip(lower=1, upper=100)
df_imputed_full = pd.concat(
    [df[["GEO", "Year", "INFRA1", "INFRA2"]], df_imputed_aux],
    axis=1
)
cols_icru = [
    "GEO", "Year",
    "GEN1", "GEN2", "GEN3",
    "TR1", "TR2", "TR3", "TR4", "TR5",
    "GOB1", "GOB2", "GOB3",
    "IMP1", "IMP2", "IMP3"
]

df_ICRU = df_imputed_full[cols_icru].copy()
cols_icru_2023 = [
    "GEO", "Year",
    "GEN1", "GEN2", "GEN3",
    "TR1", "TR2", "TR3", "TR4", "TR5",
    "INFRA1", "INFRA2",
    "GOB1", "GOB2", "GOB3",
    "IMP1", "IMP2", "IMP3"
]

# 1) Nos quedamos solo con 2023 del df_imputed_full
```

```
df_2023 = df_imputed_full[df_imputed_full["Year"] == 2023].copy()

# 2) Separamos GEO
geo_2023 = df_2023[["GEO", "Year"]].copy()

# 3) Dataset numérico (incluye INFRA1, INFRA2, INFRA3, etc.)
df_2023_num = df_2023.drop(columns=["GEO", "Year"])

# 4) Aplicamos MLR a TODO 2023 (esto imputará INFRA1 e INFRA2
también)
df_2023_num_imp = mlr_impute(df_2023_num)
df_2023_num_imp = df_2023_num_imp.clip(lower=1, upper=100)

# 5) Volvemos a juntar GEO + numérico imputado
df_2023_full = pd.concat(
    [geo_2023.reset_index(drop=True),
     df_2023_num_imp.reset_index(drop=True)],
    axis=1
)

# 6) df_ICRU_2023 final, con columnas en el orden que quieres
df_ICRU_2023 = df_2023_full[cols_icru_2023].copy()
df_ICRU.to_excel("df_ICRU.xlsx", index=False)
df_ICRU_2023.to_excel("df_ICRU_2023.xlsx", index=False)
cols_invert = ["GEN1", "GEN2", "TR5", "IMP1", "IMP2", "IMP3"]
df_ICRU[cols_invert] = 101 - df_ICRU[cols_invert]
cols_invert = ["GEN1", "GEN2", "TR5", "IMP1", "IMP2", "IMP3"]
df_ICRU_2023[cols_invert] = 101 - df_ICRU_2023[cols_invert]
dims_icru = {
    "GEN":       ["GEN1", "GEN2", "GEN3"],
    "TR":      ["TR1", "TR2", "TR3", "TR4", "TR5"],
    "GOB":       ["GOB1", "GOB2", "GOB3"],
    "IMP":          ["IMP1", "IMP2", "IMP3"],
}

pesos_icru = {}

for dim_name, vars_dim in dims_icru.items():
    weights = pesos_pca(df_ICRU[vars_dim])

    pesos_icru[dim_name] = weights

    df_ICRU[dim_name] = df_ICRU[vars_dim].mul(weights,
axis=1).sum(axis=1)

for dim_name, weights in pesos_icru.items():
    print(f"\n{dim_name}")
    print(weights)
dims_icru_2023 = {
```

```
    "GEN":      ["GEN1", "GEN2", "GEN3"],
    "TR":     ["TR1", "TR2", "TR3", "TR4", "TR5"],
    "INFRA": ["INFRA1", "INFRA2"],
    "GOB":      ["GOB1", "GOB2", "GOB3"],
    "IMP":         ["IMP1", "IMP2", "IMP3"],
}

pesos_icru_2023 = {}

for dim_name, vars_dim in dims_icru_2023.items():
    weights = pesos_pca(df_ICRU_2023[vars_dim])

    pesos_icru_2023[dim_name] = weights

    df_ICRU_2023[dim_name] = df_ICRU_2023[vars_dim].mul(weights,
axis=1).sum(axis=1)

# Ver pesos
for dim_name, weights in pesos_icru_2023.items():
    print(f"\n{dim_name}")
    print(weights)
df_ICRU["ICRU"] = df_ICRU[["GEN", "TR", "GOB", "IMP"]].mean(axis=1)
df_ICRU_2023["ICRU"] = df_ICRU_2023[["GEN", "TR", "INFRA", "GOB",
"IMP"]].mean(axis=1)
df_ICRU["ICRU"].describe()
df_ICRU.sort_values("ICRU", ascending=False)
df_ICRU_2023.sort_values("ICRU", ascending=False)
df_ICRU_eq = df_ICRU.copy()
df_ICRU_2023_eq = df_ICRU_2023.copy()

df_ICRU_eq["GEN_eq"] =
df_ICRU_eq[["GEN1","GEN2","GEN3"]].mean(axis=1)
df_ICRU_eq["TR_eq"]  =
df_ICRU_eq[["TR1","TR2","TR3","TR4","TR5"]].mean(axis=1)
df_ICRU_eq["GOB_eq"] =
df_ICRU_eq[["GOB1","GOB2","GOB3"]].mean(axis=1)
df_ICRU_eq["IMP_eq"] =
df_ICRU_eq[["IMP1","IMP2","IMP3"]].mean(axis=1)

df_ICRU_2023_eq["GEN_eq"]   =
df_ICRU_2023_eq[["GEN1","GEN2","GEN3"]].mean(axis=1)
df_ICRU_2023_eq["TR_eq"]    =
df_ICRU_2023_eq[["TR1","TR2","TR3","TR4","TR5"]].mean(axis=1)
df_ICRU_2023_eq["INFRA_eq"] =
df_ICRU_2023_eq[["INFRA1","INFRA2"]].mean(axis=1)
df_ICRU_2023_eq["GOB_eq"]   =
df_ICRU_2023_eq[["GOB1","GOB2","GOB3"]].mean(axis=1)
df_ICRU_2023_eq["IMP_eq"]   =
df_ICRU_2023_eq[["IMP1","IMP2","IMP3"]].mean(axis=1)
```

```
df_ICRU_eq["ICRU_eq"]      =
df_ICRU_eq[["GEN_eq","TR_eq","GOB_eq","IMP_eq"]].mean(axis=1)
df_ICRU_2023_eq["ICRU_eq"] =
df_ICRU_2023_eq[["GEN_eq","TR_eq","INFRA_eq","GOB_eq","IMP_eq"]].mean
(axis=1)
df_ICRU_eq[["ICRU", "ICRU_eq"]].corr()
x = df_ICRU_eq["ICRU"]
y = df_ICRU_eq["ICRU_eq"]
corr = df_ICRU_eq[["ICRU","ICRU_eq"]].corr().iloc[0,1]

plt.figure(figsize=(7,7))
plt.scatter(x, y, s=20, alpha=0.6)
lo, hi = min(x.min(), y.min()), max(x.max(), y.max())
plt.plot([lo, hi], [lo, hi], "k--", linewidth=1)
plt.text(0.05, 0.92, f"Correlación = {corr:.3f}",
         transform=plt.gca().transAxes, va="top",
         bbox=dict(boxstyle="round", fc="white", alpha=0.7))
plt.xlabel("ICRU principal"); plt.ylabel("ICRU pesos iguales")
plt.title("Pesos iguales · panel 2014-2023")
plt.grid(alpha=0.3); plt.tight_layout()
plt.show()
df_ICRU_2023_eq[["ICRU", "ICRU_eq"]].corr()
x = df_ICRU_2023_eq["ICRU"]
y = df_ICRU_2023_eq["ICRU_eq"]
corr = df_ICRU_2023_eq[["ICRU","ICRU_eq"]].corr().iloc[0,1]

plt.figure(figsize=(7,7))
plt.scatter(x, y, s=20, alpha=0.6)
lo, hi = min(x.min(), y.min()), max(x.max(), y.max())
plt.plot([lo, hi], [lo, hi], "k--", linewidth=1)
plt.text(0.05, 0.92, f"Correlación = {corr:.3f}",
         transform=plt.gca().transAxes, va="top",
         bbox=dict(boxstyle="round", fc="white", alpha=0.7))
plt.xlabel("ICRU principal"); plt.ylabel("ICRU pesos iguales")
plt.title("Pesos iguales · 2023")
plt.grid(alpha=0.3); plt.tight_layout()
plt.show()
dims_temp = ["GEN", "TR", "GOB", "IMP"]
dims_2023 = ["GEN", "TR", "INFRA", "GOB", "IMP"]
df_ICRU["ICRU_geom"] =
np.exp(np.log(df_ICRU[dims_temp]).mean(axis=1))

df_ICRU[["ICRU", "ICRU_geom"]].corr()
x = df_ICRU["ICRU"]
y = df_ICRU["ICRU_geom"]
corr = df_ICRU[["ICRU","ICRU_geom"]].corr().iloc[0,1]

plt.figure(figsize=(7,7))
```

```
plt.scatter(x, y, s=20, alpha=0.6)
lo, hi = min(x.min(), y.min()), max(x.max(), y.max())
plt.plot([lo, hi], [lo, hi], "k--", linewidth=1)
plt.text(0.05, 0.92, f"Correlación = {corr:.3f}",
         transform=plt.gca().transAxes, va="top",
         bbox=dict(boxstyle="round", fc="white", alpha=0.7))
plt.xlabel("ICRU principal"); plt.ylabel("ICRU geométrica")
plt.title("Agregación geométrica · panel 2014-2023")
plt.grid(alpha=0.3); plt.tight_layout()
plt.show()
df_ICRU_2023["ICRU_geom"] =
np.exp(np.log(df_ICRU_2023[dims_2023]).mean(axis=1))

df_ICRU_2023[["ICRU", "ICRU_geom"]].corr()
x = df_ICRU_2023["ICRU"]
y = df_ICRU_2023["ICRU_geom"]
corr = df_ICRU_2023[["ICRU","ICRU_geom"]].corr().iloc[0,1]

plt.figure(figsize=(7,7))
plt.scatter(x, y, s=20, alpha=0.6)
lo, hi = min(x.min(), y.min()), max(x.max(), y.max())
plt.plot([lo, hi], [lo, hi], "k--", linewidth=1)
plt.text(0.05, 0.92, f"Correlación = {corr:.3f}",
         transform=plt.gca().transAxes, va="top",
         bbox=dict(boxstyle="round", fc="white", alpha=0.7))
plt.xlabel("ICRU principal"); plt.ylabel("ICRU geométrica")
plt.title("Agregación geométrica · 2023")
plt.grid(alpha=0.3); plt.tight_layout()
plt.show()
df_rank = df_ICRU.copy()
df_rank["Rank"] =
df_rank.groupby("Year")["ICRU"].rank(ascending=False, method="min")

# 2. Pivotar para tener años en filas y países en columnas
rank_pivot = df_rank.pivot(index="Year", columns="GEO",
values="Rank")

# 3. Graficar
plt.figure(figsize=(14, 8))

for country in rank_pivot.columns:
    plt.plot(rank_pivot.index, rank_pivot[country], marker="o",
linewidth=1, label=country)

plt.gca().invert_yaxis()  # para que el puesto 1 salga arriba
plt.xlabel("Year")
plt.ylabel("Ranking")
plt.title("Evolución del ranking de países según el ICRU")
plt.grid(True, alpha=0.3)
```

```
plt.legend(bbox_to_anchor=(1.05, 1), loc="upper left", fontsize=8)
plt.tight_layout()
plt.show()
df_rank = df_ICRU.copy()
df_rank["Rank"] =
df_rank.groupby("Year")["ICRU"].rank(ascending=False, method="min")

ultimo_anio = df_rank["Year"].max()

top5 = df_rank[df_rank["Year"] == ultimo_anio].nsmallest(5,
"Rank")["GEO"]
bottom5 = df_rank[df_rank["Year"] == ultimo_anio].nlargest(5,
"Rank")["GEO"]

subset = pd.concat([top5, bottom5]).unique()

df_subset = df_rank[df_rank["GEO"].isin(subset)]

rank_pivot = df_subset.pivot(index="Year", columns="GEO",
values="Rank")

plt.figure(figsize=(12, 7))

for country in rank_pivot.columns:
    plt.plot(rank_pivot.index, rank_pivot[country], marker="o",
linewidth=2, label=country)

plt.gca().invert_yaxis()
plt.xlabel("Year")
plt.ylabel("Ranking")
plt.title(f"Evolución del ranking (Top & Bottom países en
{ultimo_anio})")
plt.grid(True, alpha=0.3)
plt.legend()
plt.tight_layout()
plt.show()
subset = ["Iceland", "Czechia", "Türkiye"]
df_sub = df_ICRU[df_ICRU["GEO"].isin(subset)].copy()

plt.figure(figsize=(10,6))

for country in subset:
    data = df_sub[df_sub["GEO"] == country]
    plt.plot(data["Year"], data["ICRU"], marker="o", label=country)

plt.xlabel("Year")
plt.ylabel("ICRU")
plt.title("Evolución del ICRU")
plt.legend()
```

```
plt.grid(alpha=0.3)
plt.show()
dims = ["GEN", "TR", "GOB", "IMP"]

for country in subset:
    print("\n", country)
    print(df_sub[df_sub["GEO"] == country][["Year"] + dims])
colors = {
    "Iceland": "blue",
    "Czechia": "red",
    "Türkiye": "green"
}

# Estilos por dimensión
linestyles = {
    "GEN": "-",
    "TR": "--",
    "GOB": ":",
    "IMP": "-."
}

plt.figure(figsize=(12,6))

for country in subset:
    df_c = df_sub[df_sub["GEO"] == country]

    for dim in dims:
        plt.plot(
            df_c["Year"],
            df_c[dim],
            color=colors[country],
            linestyle=linestyles[dim],
            label=f"{country} - {dim}"
        )

plt.xlabel("Year")
plt.ylabel("Valor dimensión")
plt.title("Evolución por dimensiones y país")
plt.grid(alpha=0.3)

# Quitar duplicados en leyenda
handles, labels = plt.gca().get_legend_handles_labels()
unique = dict(zip(labels, handles))
plt.legend(unique.values(), unique.keys(), bbox_to_anchor=(1.05,1))

plt.tight_layout()
plt.show()
df_ICRU = df_ICRU.merge(
    df_panel[["GEO", "Year", "GDP"]],
```

```
    on=["GEO", "Year"],
    how="left"
)
df_ICRU[["ICRU", "GDP"]].corr()
plt.figure(figsize=(8,6))

plt.scatter(df_ICRU["GDP"], df_ICRU["ICRU"])

plt.xlabel("GDP")
plt.ylabel("ICRU")
plt.title("Relación entre GDP e ICRU (2023)")
plt.grid(alpha=0.3)

plt.show()

df_map = df_ICRU_2023[["GEO", "ICRU"]].copy()

# 2) Cargar el mapa mundial y quedarnos con Europa
url =
"https://naciscdn.org/naturalearth/110m/cultural/ne_110m_admin_0_coun
tries.zip"
world = gpd.read_file(url)

# 3) Homogeneizar nombres (los de Natural Earth vs los tuyos)
rename = {
    "Czechia": "Czechia", "Czech Rep.": "Czechia",
    "Bosnia and Herz.": "Bosnia and Herzegovina",
    "North Macedonia": "North Macedonia",
    "Slovakia": "Slovakia",
}
world["NAME"] = world["NAME"].replace(rename)

# Unir
europe = world.merge(df_map, left_on="NAME", right_on="GEO",
how="left")

# 4) Recortar a la ventana europea
fig, ax = plt.subplots(1, 1, figsize=(12, 12))

europe.plot(
    column="ICRU",
    cmap="RdYlGn",
    linewidth=0.5,
    edgecolor="grey",
    legend=True,
    legend_kwds={"label": "ICRU 2023", "shrink": 0.6},
    missing_kwds={"color": "lightgrey"},
    ax=ax,
)
```

```
# Acotar la vista a Europa continental (longitud, latitud)
ax.set_xlim(-13, 35)
ax.set_ylim(34, 72)

ax.set_title("Índice de Circularidad de Residuos Urbanos (ICRU) por
país, 2023", fontsize=14)
ax.axis("off")
plt.savefig("mapa_icru_2023.png", dpi=300, bbox_inches="tight")
plt.show()

ranking_2023 = (
    df_ICRU_2023[["GEO", "ICRU"]]
    .sort_values("ICRU", ascending=False)
    .reset_index(drop=True)
)
ranking_2023.index += 1
ranking_2023["ICRU"] = ranking_2023["ICRU"].round(1)

# 2) Construir las filas: posición, país, valor
filas = [[str(i), pais, f"{val:.1f}"]
         for i, (pais, val) in enumerate(zip(ranking_2023["GEO"],
ranking_2023["ICRU"]), start=1)]

# 3) Dibujar la tabla
fig, ax = plt.subplots(figsize=(6, len(filas) * 0.35 + 1))
ax.axis("off")

tabla = ax.table(
    cellText=filas,
    colLabels=["#", "País", "ICRU 2023"],
    cellLoc="center",
    loc="center",
)
tabla.auto_set_font_size(False)
tabla.set_fontsize(11)
tabla.scale(1, 1.4)

# 4) Estilo: cabecera en verde, filas alternas en gris claro
for (fila, col), celda in tabla.get_celld().items():
    if fila == 0:  # cabecera
        celda.set_facecolor("#2e7d32")
        celda.set_text_props(color="white", fontweight="bold")
    elif fila % 2 == 0:
        celda.set_facecolor("#f2f2f2")
    celda.set_edgecolor("#cccccc")

plt.title("Ranking del ICRU 2023", fontsize=13, fontweight="bold",
pad=15)
```

```
plt.savefig("tabla_ranking_2023.png", dpi=300, bbox_inches="tight")
plt.show()

dims = ["GEN", "TR", "INFRA", "GOB", "IMP"]
dim_labels = ["Generación", "Tratamiento", "Infraest.", "Gobernanza",
"Impacto"]

# Países a mostrar: top 5 y bottom 5 del ranking 2023
df_r = df_ICRU_2023.sort_values("ICRU",
ascending=False).reset_index(drop=True)
top = df_r.head(5)
bottom = df_r.tail(5)
sel = pd.concat([top, bottom])

# Construir filas: país, cada dimensión, e ICRU total
filas = []
for _, r in sel.iterrows():
    fila = [r["GEO"]] + [f"{r[d]:.1f}" for d in dims] +
[f"{r['ICRU']:.1f}"]
    filas.append(fila)

fig, ax = plt.subplots(figsize=(10, len(filas) * 0.45 + 1))
ax.axis("off")

tabla = ax.table(
    cellText=filas,
    colLabels=["País"] + dim_labels + ["ICRU"],
    cellLoc="center",
    loc="center",
)
tabla.auto_set_font_size(False)
tabla.set_fontsize(10)
tabla.scale(1, 1.5)

# Estilo: cabecera verde, separador entre top y bottom
n_top = len(top)
for (fila, col), celda in tabla.get_celld().items():
    if fila == 0:
        celda.set_facecolor("#2e7d32")
        celda.set_text_props(color="white", fontweight="bold")
    elif fila == n_top:  # primera fila del grupo bottom, línea de
separación gruesa
        celda.set_edgecolor("black")
        celda.set_linewidth(2)
    # última columna (ICRU) resaltada
    if col == len(dims) + 1 and fila > 0:
        celda.set_facecolor("#e8f5e9")
        celda.set_text_props(fontweight="bold")
```

```
plt.title("Puntuación por dimensión: países líderes y rezagados (ICRU
2023)",
          fontsize=12, fontweight="bold", pad=15)
plt.savefig("tabla_dimensiones_2023.png", dpi=300,
bbox_inches="tight")
plt.show()

dims_icru = {
    "GEN": ["GEN1","GEN2","GEN3"],
    "TR":  ["TR1","TR2","TR3","TR4","TR5"],
    "GOB": ["GOB1","GOB2","GOB3"],
    "IMP": ["IMP1","IMP2","IMP3"],
}
dims_icru_2023 = {
    "GEN": ["GEN1","GEN2","GEN3"],
    "TR":  ["TR1","TR2","TR3","TR4","TR5"],
    "INFRA": ["INFRA1","INFRA2"],
    "GOB": ["GOB1","GOB2","GOB3"],
    "IMP": ["IMP1","IMP2","IMP3"],
}

def shift_medio(df, col_base, col_alt, group_col=None):
    d = df.copy()
    if group_col:
        d["rb"] =
d.groupby(group_col)[col_base].rank(ascending=False, method="min")
        d["ra"] = d.groupby(group_col)[col_alt].rank(ascending=False,
method="min")
    else:
        d["rb"] = d[col_base].rank(ascending=False, method="min")
        d["ra"] = d[col_alt].rank(ascending=False, method="min")
    return (d["rb"] - d["ra"]).abs().mean()

def construir_indice(df, dims_dict, modo):
    """modo='pesos_iguales' -> cada dimensión es la media simple de
SUS INDICADORES."""
    d = df.copy()
    dim_cols = []
    for dim, indicadores in dims_dict.items():
        col = f"{dim}_eqw"
        d[col] = d[indicadores].mean(axis=1)    # indicadores con peso
igual
        dim_cols.append(col)
    # Agregación final: media de las dimensiones
    return d[dim_cols].mean(axis=1)

# Índice con PESOS IGUALES de indicadores (reconstruido desde cero)
df_ICRU["ICRU_eqw"]      = construir_indice(df_ICRU, dims_icru,
"pesos_iguales")
```

```
df_ICRU_2023["ICRU_eqw"] = construir_indice(df_ICRU_2023,
dims_icru_2023, "pesos_iguales")

# Media geométrica de las dimensiones (las columnas GEN/TR/... que ya
tienes, con pesos PCA dentro)
dims_temp = ["GEN","TR","GOB","IMP"]
dims_2023 = ["GEN","TR","INFRA","GOB","IMP"]
df_ICRU["ICRU_geom"]      =
np.exp(np.log(df_ICRU[dims_temp]).mean(axis=1))
df_ICRU_2023["ICRU_geom"] =
np.exp(np.log(df_ICRU_2023[dims_2023]).mean(axis=1))

print("===== PANEL 2014-2023 =====")
print(f"Pesos iguales vs PCA     : {shift_medio(df_ICRU, 'ICRU',
'ICRU_eqw', 'Year'):.2f} posiciones")
print(f"Geométrica vs aritmética : {shift_medio(df_ICRU, 'ICRU',
'ICRU_geom', 'Year'):.2f} posiciones")

print("\n===== CORTE 2023 =====")
print(f"Pesos iguales vs PCA     : {shift_medio(df_ICRU_2023, 'ICRU',
'ICRU_eqw'):.2f} posiciones")
print(f"Geométrica vs aritmética : {shift_medio(df_ICRU_2023, 'ICRU',
'ICRU_geom'):.2f} posiciones")
eq_panel   = shift_medio(df_ICRU, 'ICRU', 'ICRU_eqw', 'Year')
geom_panel = shift_medio(df_ICRU, 'ICRU', 'ICRU_geom', 'Year')
eq_2023    = shift_medio(df_ICRU_2023, 'ICRU', 'ICRU_eqw')
geom_2023  = shift_medio(df_ICRU_2023, 'ICRU', 'ICRU_geom')

filas = [
    ["Pesos iguales (vs
PCA)",       f"{eq_panel:.2f}",   f"{eq_2023:.2f}"],
    ["Media geométrica (vs aritmética)", f"{geom_panel:.2f}",
f"{geom_2023:.2f}"],
]

fig, ax = plt.subplots(figsize=(10, 2))
ax.axis("off")

tabla = ax.table(
    cellText=filas,
    colLabels=["Especificación alternativa", "Desp. medio\n(panel
2014-2023)", "Desp. medio\n(2023)"],
    cellLoc="center",
    loc="center",
)
tabla.auto_set_font_size(False)
tabla.set_fontsize(10)
tabla.scale(1, 2)
```

```
# Ensanchar la primera columna y estrechar las otras dos
anchos = {0: 0.55, 1: 0.225, 2: 0.225}
for (fila, col), celda in tabla.get_celld().items():
    celda.set_width(anchos[col])
    if fila == 0:
        celda.set_facecolor("#2e7d32")
        celda.set_text_props(color="white", fontweight="bold")
    elif fila % 2 == 0:
        celda.set_facecolor("#f2f2f2")
    celda.set_edgecolor("#cccccc")

# Alinear a la izquierda el texto de la primera columna (queda mejor
con texto largo)
for fila in range(1, len(filas) + 1):
    tabla[(fila, 0)].set_text_props(ha="left")
    tabla[(fila, 0)].PAD = 0.03

plt.title("Análisis de robustez del ICRU: desplazamiento medio de
posiciones",
          fontsize=12, fontweight="bold", pad=15)
plt.savefig("tabla_robustez.png", dpi=300, bbox_inches="tight")
plt.show()
```

7.1.2 Código R

```
library(readxl)
library(psych)
library(corrplot)
library(factoextra)
library(cluster)
library(ggplot2)
library(gridExtra)
library(pheatmap)
library(dendextend)
library(reshape2)
df_ICRU <- read_excel("df_ICRU.xlsx")
df_ICRU_2023 <- read_excel("df_ICRU_2023.xlsx")
df_icru_num <- df_ICRU[, !(names(df_ICRU) %in% c("GEO", "Year"))]
cor_icru <- cor(df_icru_num, use = "pairwise.complete.obs")
round(cor_icru, 2)
corrplot(cor_icru, method = "color", tl.cex = 0.7, number.cex = 0.5)
```

```
df_icru_2023_num <- df_ICRU_2023[, !(names(df_ICRU_2023) %in% c("GEO", "Year"))]
cor_icru_2023 <- cor(df_icru_2023_num, use = "pairwise.complete.obs")
round(cor_icru_2023, 2)
corrplot(cor_icru_2023, method = "color", tl.cex = 0.7, number.cex = 0.5)
KMO(cor_icru)
KMO(cor_icru_2023)
pcs <- prcomp(df_icru_num, scale. = TRUE)
summary(pcs)
PVE <- summary(pcs)$importance[2,]
PVE_acum <- summary(pcs)$importance[3,]
par(mfrow = c(1, 2))
plot(PVE, xlab="Componente principal", ylab="PVE", ylim=c(0,1), type="b")
plot(PVE_acum, xlab="Componente principal", ylab="PVE acumulada", ylim=c(0,1), type="b")
par(mfrow = c(1,1))
eigen_values <- pcs$sdev^2
eigen_values
loadings_3pc <- pcs$rotation[, 1:3]
round(loadings_3pc, 3)
fviz_pca_biplot(
pcs,
geom.ind = "point",
pointshape = 19,
pointsize = 1,
alpha.ind = 0.4,
col.ind = "grey60",
label = "var",
repel = TRUE, # evita solapamiento de etiquetas
col.var = "red",
arrowsize = 0.8,
labelsize = 4datanorm <- scale(df_icru_num)
dist_euclidean <- dist(datanorm, method = "euclidean")
dist_manhattan <- dist(datanorm, method = "manhattan")
```

```
cor_matrix <- cor(t(datanorm))
dist_correlation <- as.dist(1 - cor_matrix)
plot_euclidean <- fviz_dist(dist_euclidean) + ggtitle("Euclidean Distance")
plot_manhattan <- fviz_dist(dist_manhattan) + ggtitle("Manhattan Distance")
plot_correlation <- fviz_dist(dist_correlation) + ggtitle("Correlation Distance")
grid.arrange(plot_euclidean, plot_manhattan, plot_correlation, ncol = 2)
dist_matrix <- dist_euclidean
hc_single <- hclust(dist_matrix, method = "single")
hc_complete <- hclust(dist_matrix, method = "complete")
hc_average <- hclust(dist_matrix, method = "average")
hc_ward <- hclust(dist_matrix, method = "ward.D2")
hc_centroid <- hclust(dist_matrix, method = "centroid")
plot(hc_single, main = "Single Linkage", cex = 0.6)
plot(hc_complete, main = "Complete Linkage", cex = 0.6)
plot(hc_average, main = "Average Linkage", cex = 0.6)
plot(hc_ward, main = "Ward's Method", cex = 0.6)
plot(hc_centroid, main = "Centroid Method", cex = 0.6)
dend_complete <- fviz_dend(hc_complete, k = 2, main = "Complete Linkage")
dend_complete
dend_ward <- fviz_dend(hc_ward, k = 2, main = "Ward Linkage")
dend_ward
dist_matrix <- dist_manhattan
dend_complete <- fviz_dend(hc_complete, k = 2, main = "Complete Linkage")
dend_complete
dend_ward <- fviz_dend(hc_ward, k = 2, main = "Ward Linkage")
dend_ward
dist_matrix <- dist_correlation
dend_complete <- fviz_dend(hc_complete, k = 2, main = "Complete Linkage")
dend_complete
dend_ward <- fviz_dend(hc_ward, k = 2, main = "Ward Linkage")
dend_ward
mat <- scale(df_icru_num)
pheatmap(mat,
clustering_distance_rows = "euclidean",
```

```
clustering_distance_cols = "euclidean",
clustering_method = "ward.D2",
color = colorRampPalette(c("blue", "white", "red"))(200),
fontsize_row = 5,
fontsize_col = 10,
main = "Heatmap con Dendrograma – ICRU")
dist_euclidean <- dist(datanorm, method = "euclidean")
hc_ward <- hclust(dist_euclidean, method = "ward.D2")
clusters_ward <- cutree(hc_ward, k = 2)
table(clusters_ward)
fviz_cluster(list(data = datanorm, cluster = clusters_ward))
sil <- silhouette(clusters_ward, dist_euclidean)
fviz_silhouette(sil) +
ggtitle("Silhouette – Ward.D2 con Distancia Euclídea")
centroids <- aggregate(datanorm,
by = list(cluster = clusters_ward),
FUN = mean)
Centroids
centroids_long <- melt(centroids, id.vars = "cluster")
ggplot(centroids_long, aes(x = variable,
y = value,
group = factor(cluster),
color = factor(cluster))) +
geom_line(size = 1.2) +
geom_point(size = 2) +
theme_bw() +
theme(axis.text.x = element_text(angle = 60, hjust = 1),
plot.title = element_text(size = 14, face = "bold")) +
labs(title = "Perfiles de Centroides por Cluster (ICRU)",
x = "Variables",
y = "Valor medio del
```

7.2 Figuras

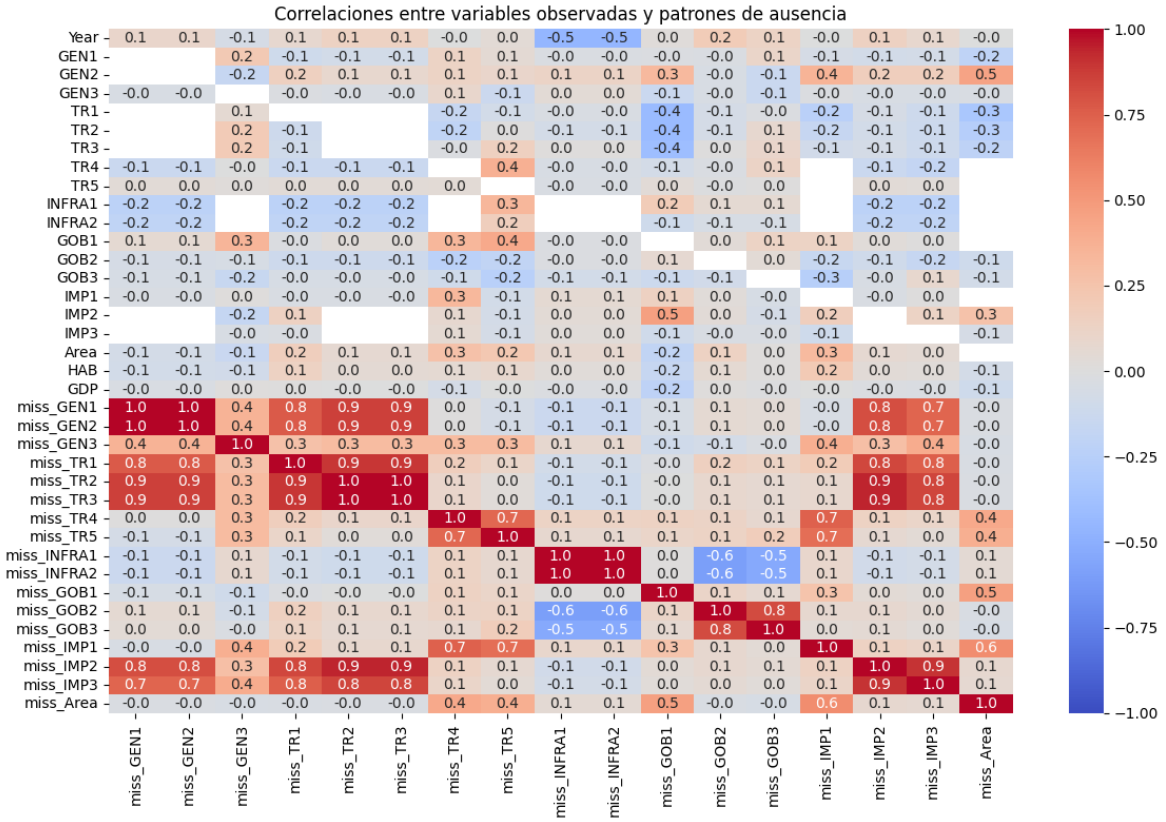


Figura 12. Matriz de correlación de valores faltantes.

	ICRU	ICRU_eq
ICRU	1.000000	0.959646
ICRU_eq	0.959646	1.000000

Tabla 9. Correlación de ICRU con ICRU agregado con pesos iguales.

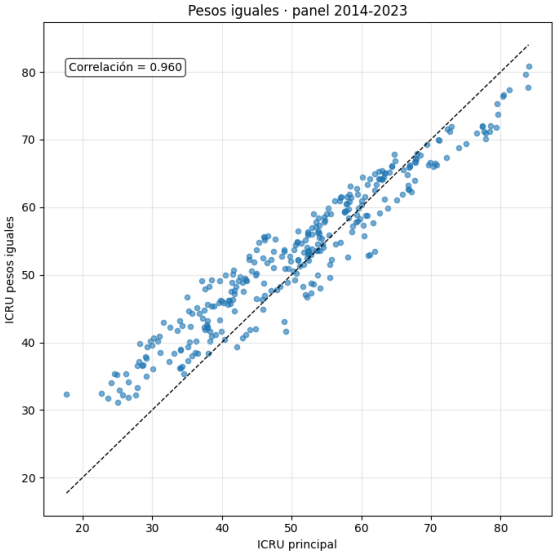


Figura 13. Visualización ICRU x. ICRU_eq.

	ICRU	ICRU_eq
ICRU	1.000000	0.965486
ICRU_eq	0.965486	1.000000

Tabla 10. Correlación de ICRU_2023 con ICRU_2023 agregado con pesos iguales.

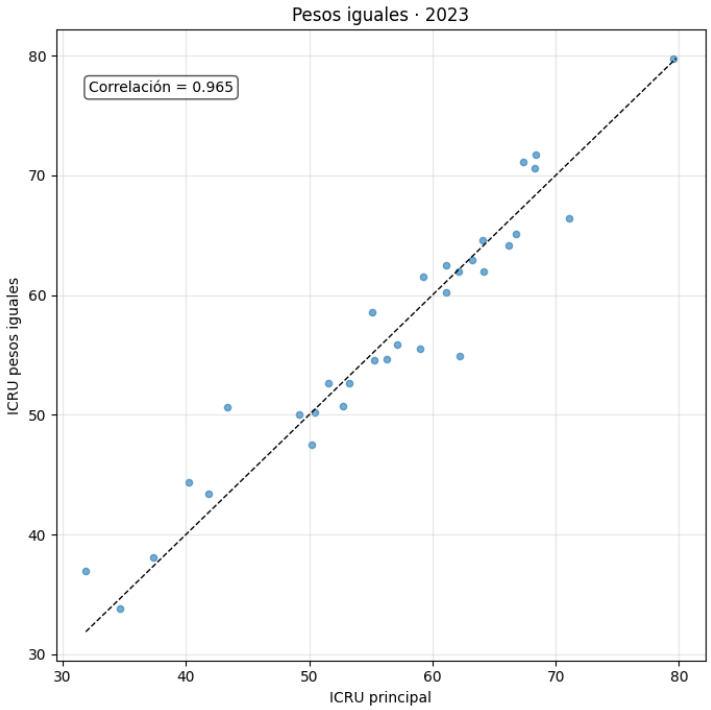


Figura 14. Visualización ICRU_2023 x. ICRU_2023_eq.

	ICRU	ICRU_geom
ICRU	1.000000	0.982892
ICRU_geom	0.982892	1.000000

Tabla 11. Correlación de ICRU con ICRU_geom.

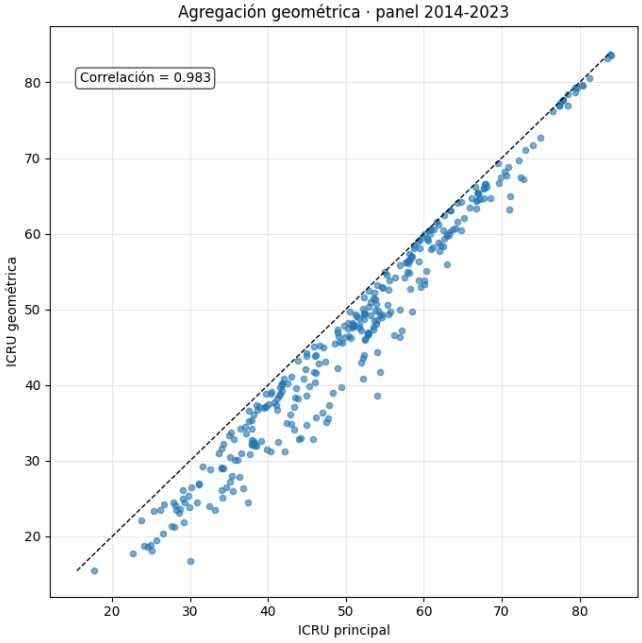


Figura 15. Visualización ICRU x. ICRU_geom.

	ICRU	ICRU_geom
ICRU	1.000000	0.986839
ICRU_geom	0.986839	1.000000

Tabla 12. Correlación de ICRU_2023 con ICRU_2023_geom.

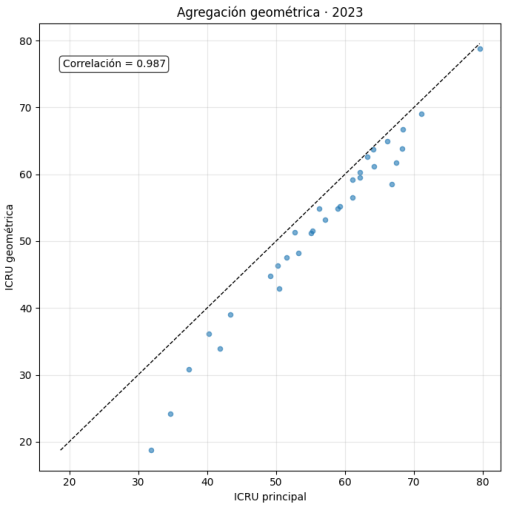


Figura 16. Visualización ICRU_2023 x. ICRU_2023_geom.

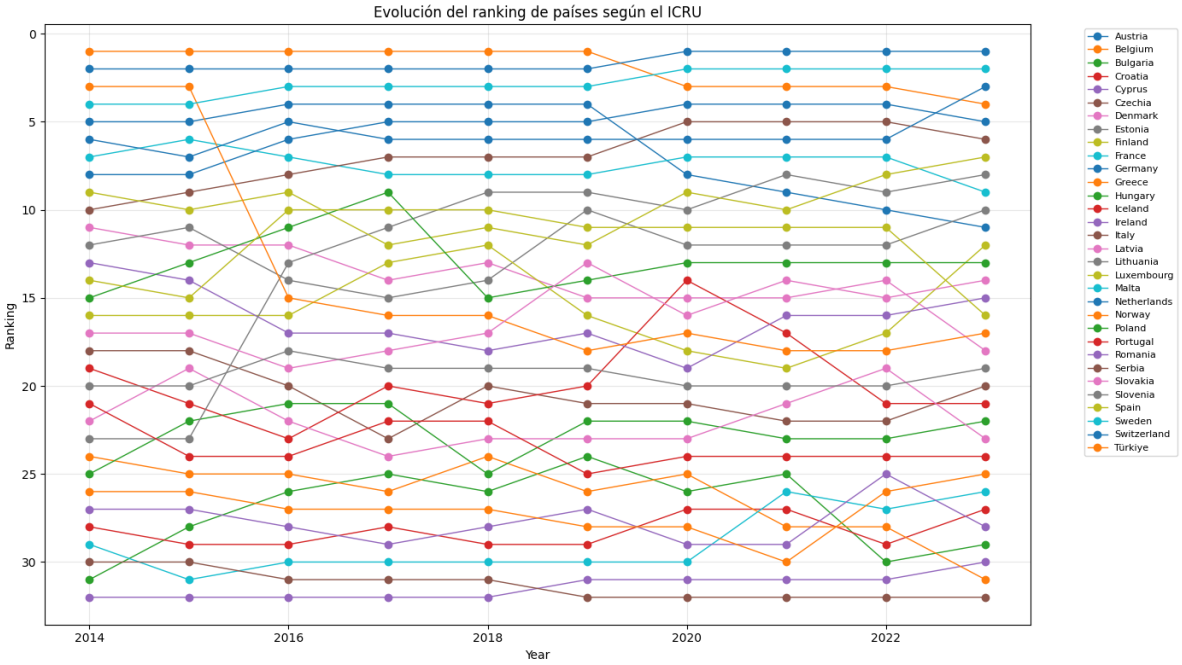


Figura 17. Evolución de ranking de países según ICRU.

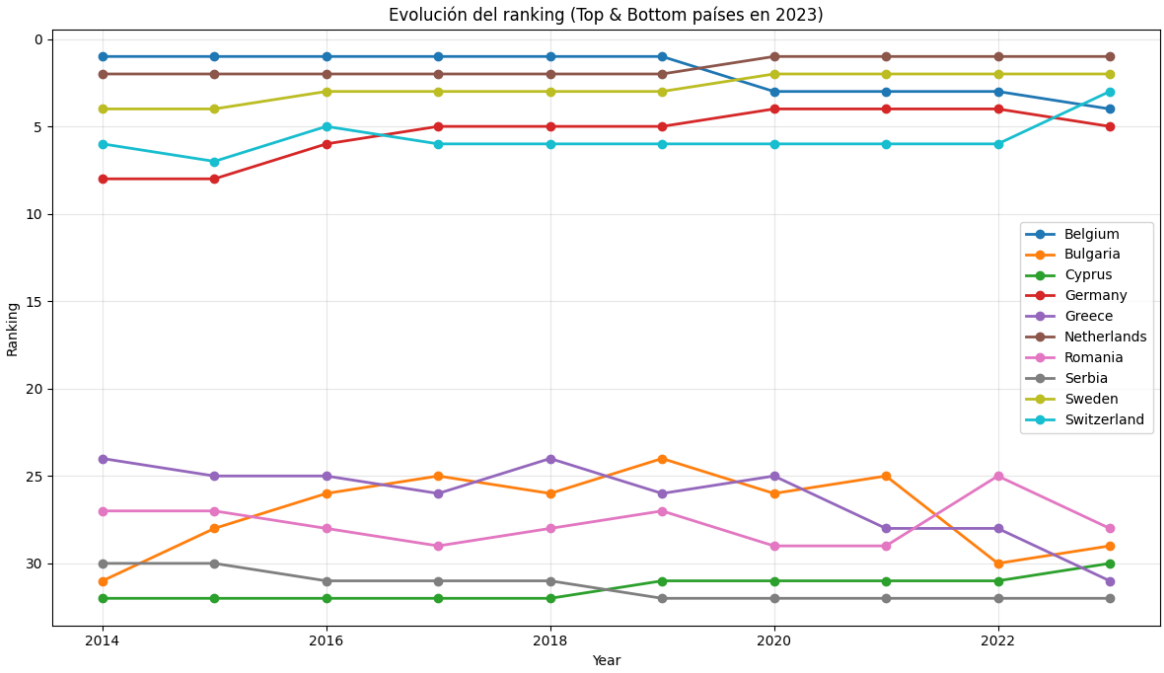


Figura 18. Evolución de ranking de top 10 y bottom 10 países según ICRU.

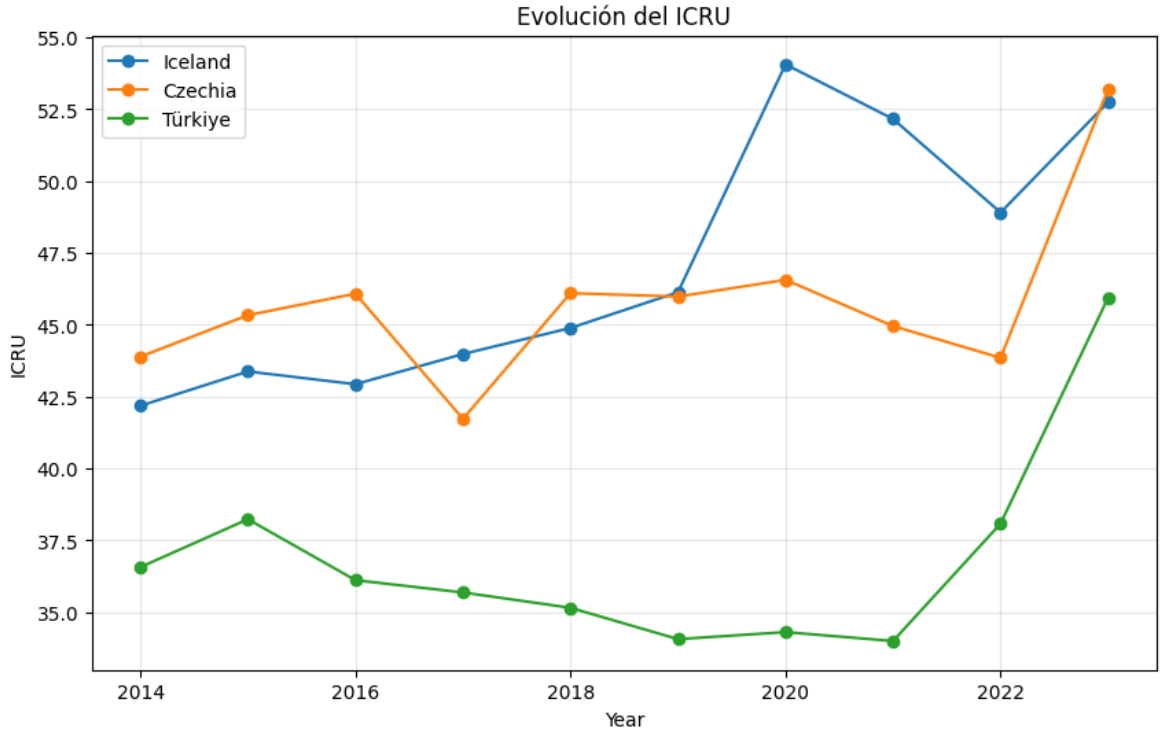


Figura 19. Evolución de ICRU para subset de países.

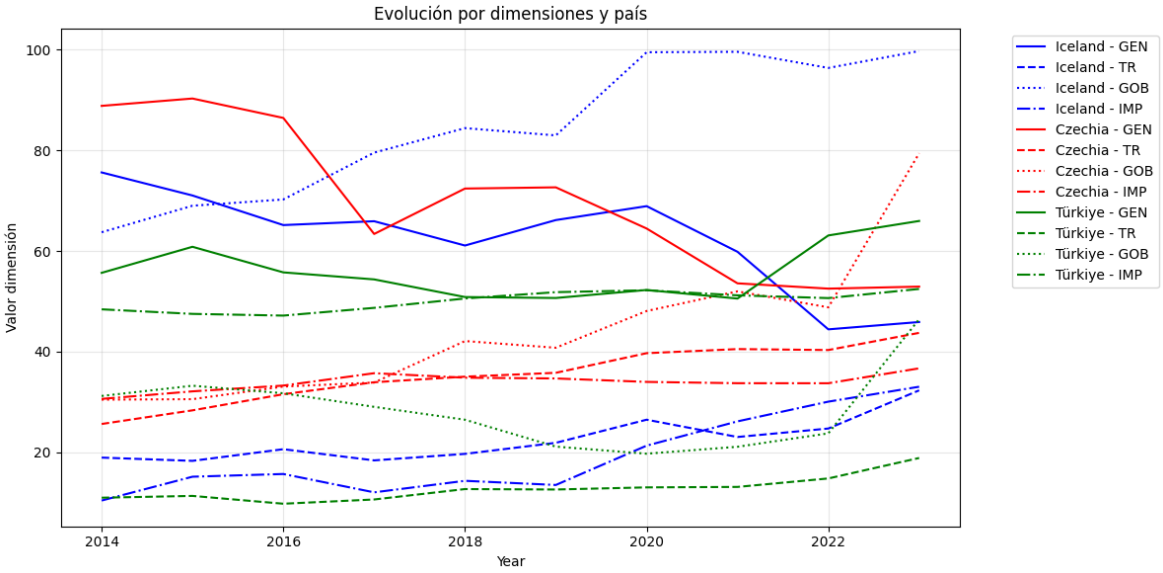


Figura 20. Evolución por dimensiones de ICRU para subset de países.

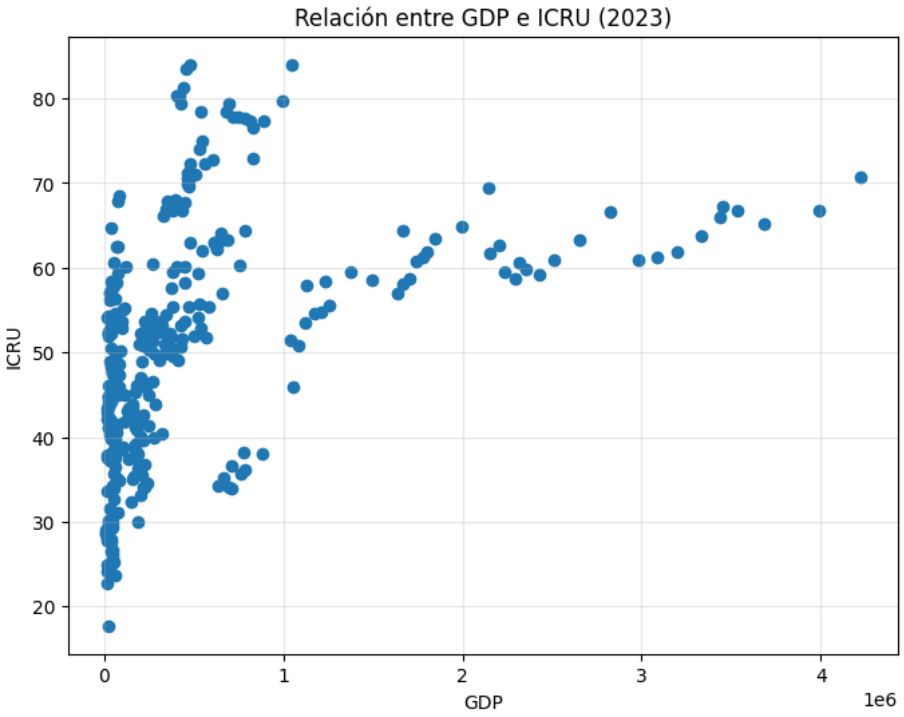


Figura 21. Relación entre ICRU y GDP (2023).

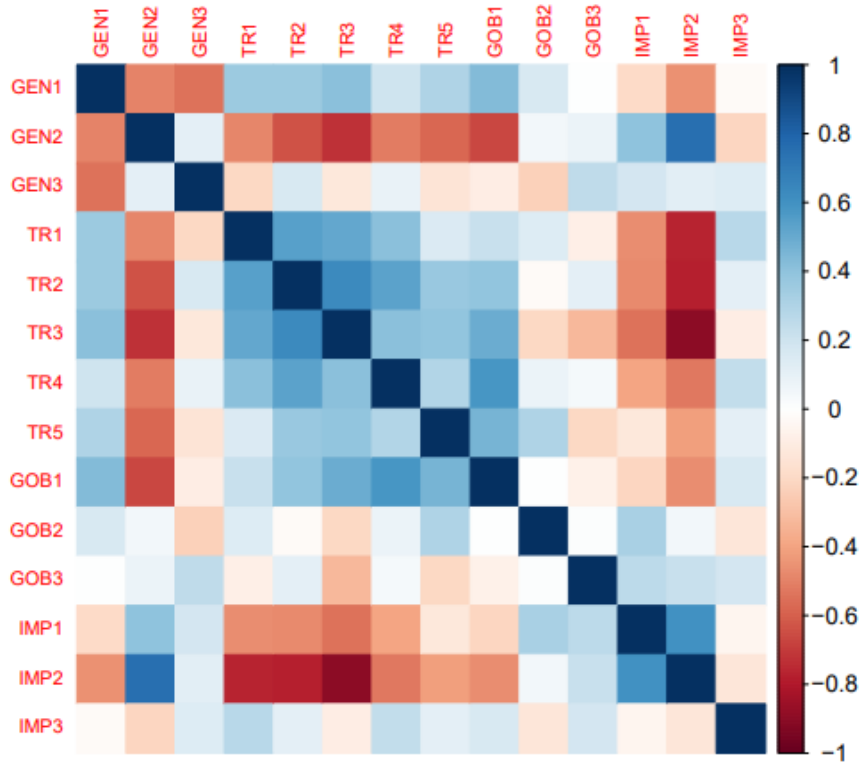


Figura 22. Matriz de correlación de variables de ICRU.

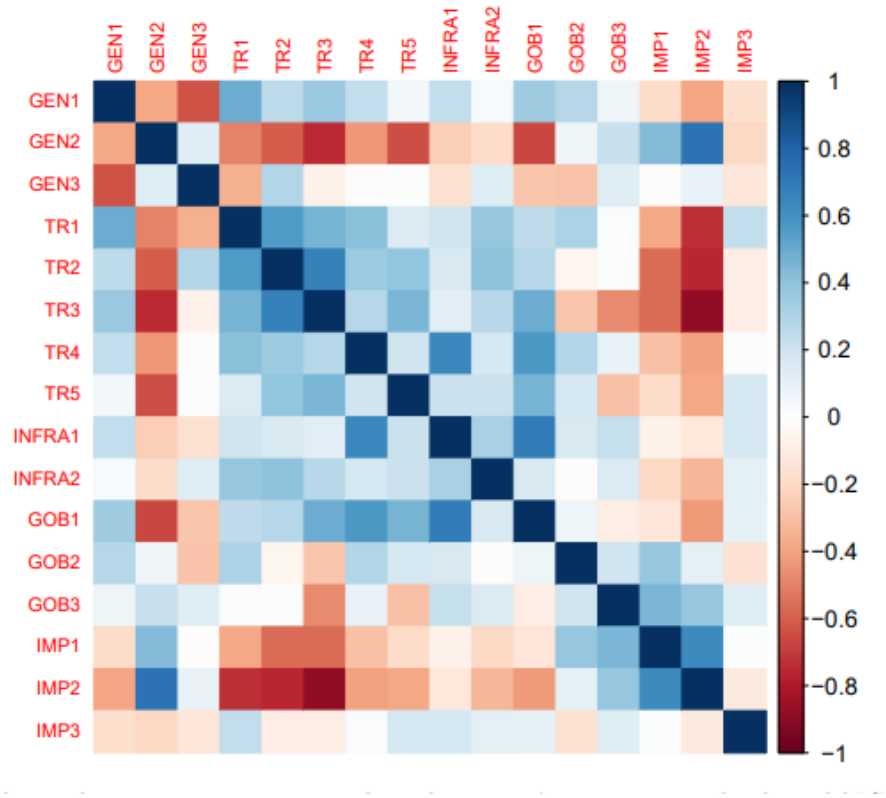


Figura 23. Matriz de correlación de variables de ICRU_2023.

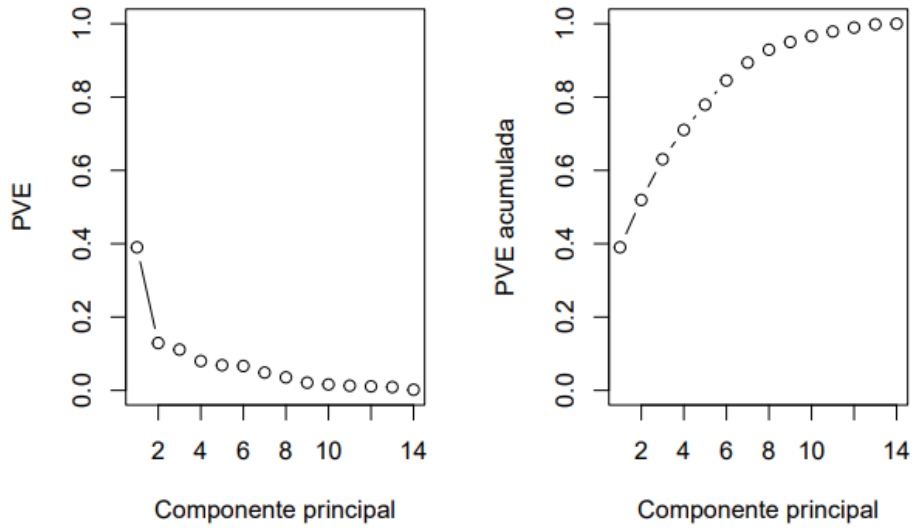


Figura 24. Análisis de PVE.

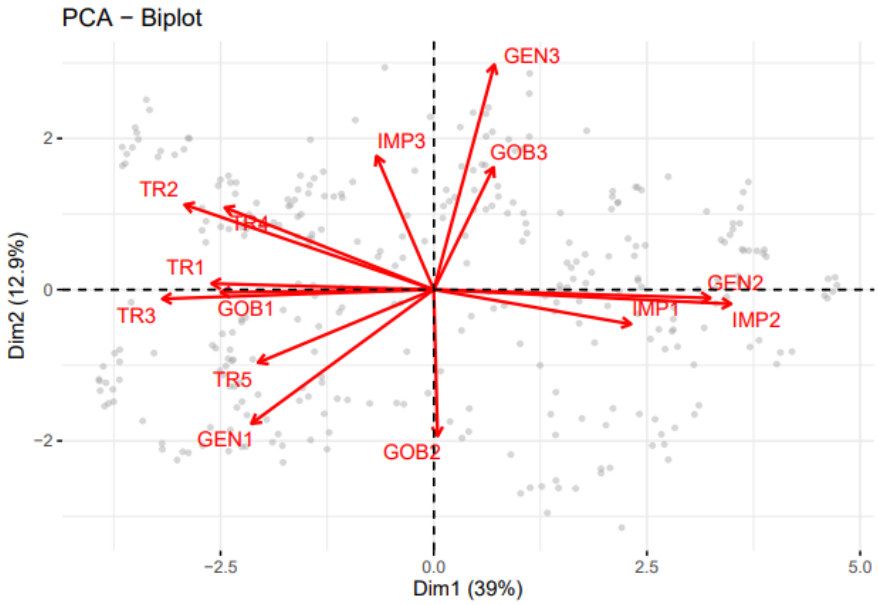


Figura 25. PCA biplot.

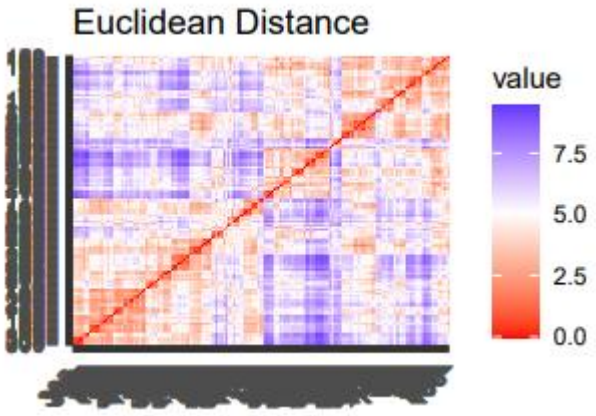


Figura 26. Matriz de distancia euclidiana.

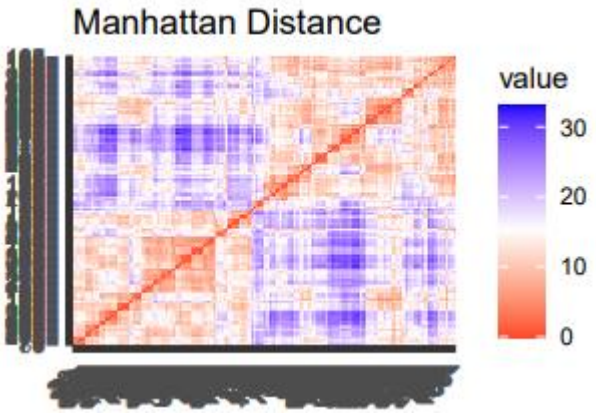


Figura 27. Matriz de distancia Manhattan.

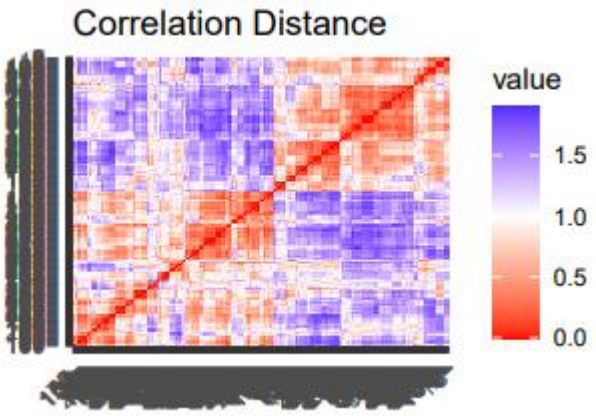


Figura 28. Matriz de distancia correlada.

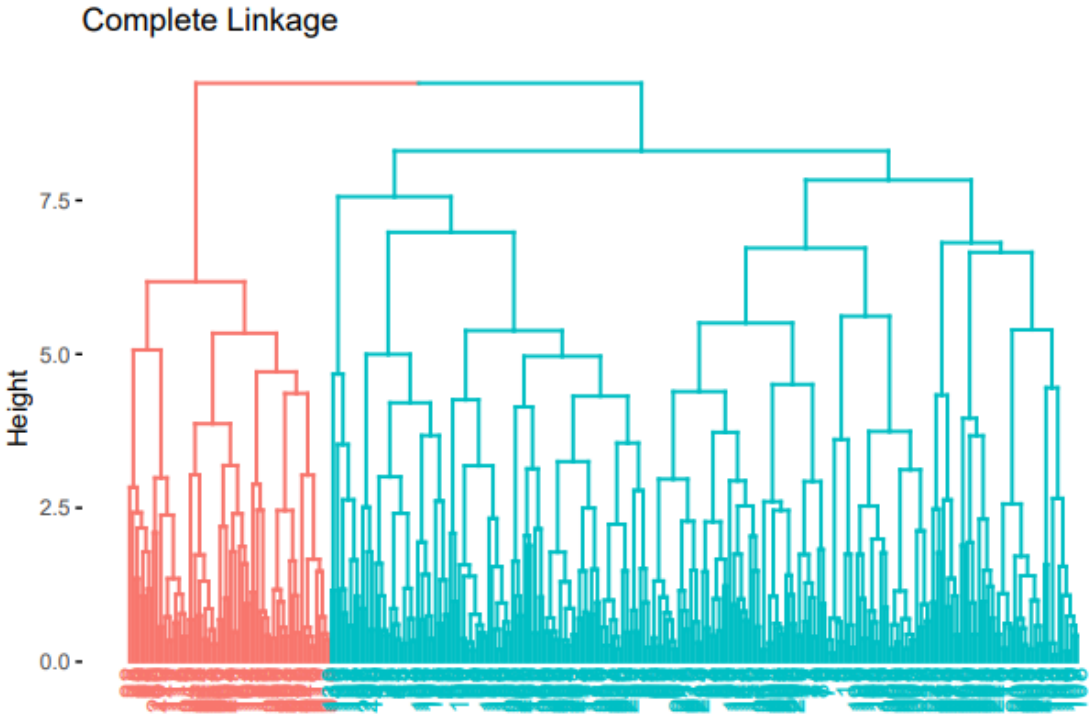


Figura 29. Dendograma con distancia euclidiana y criterio Complete.

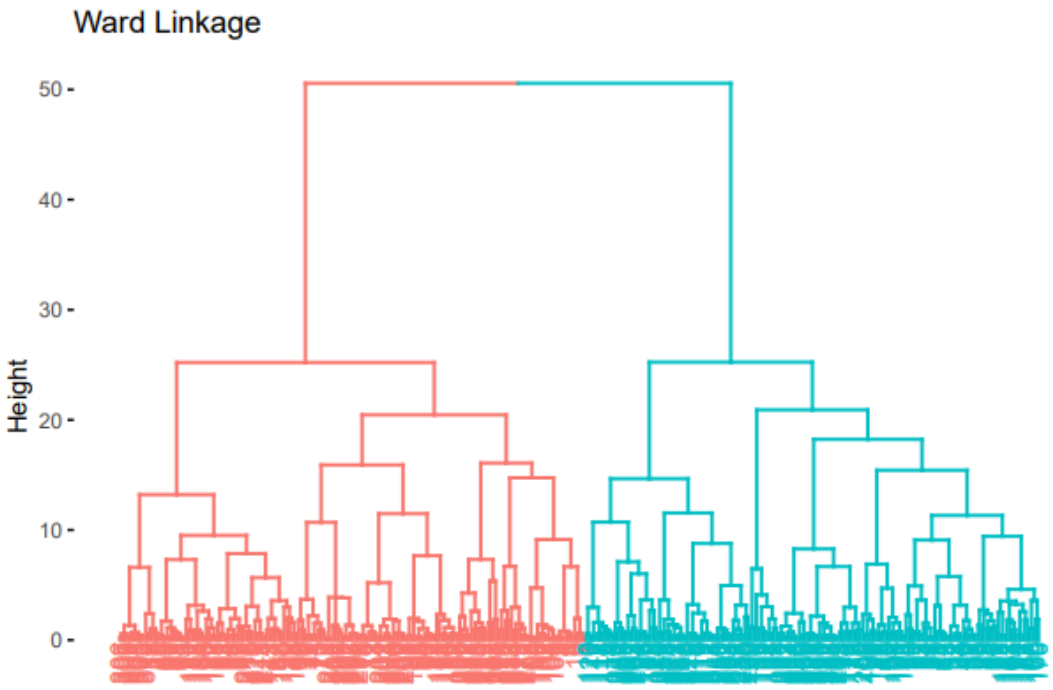


Figura 30. Dendograma con distancia euclidiana y criterio Ward.

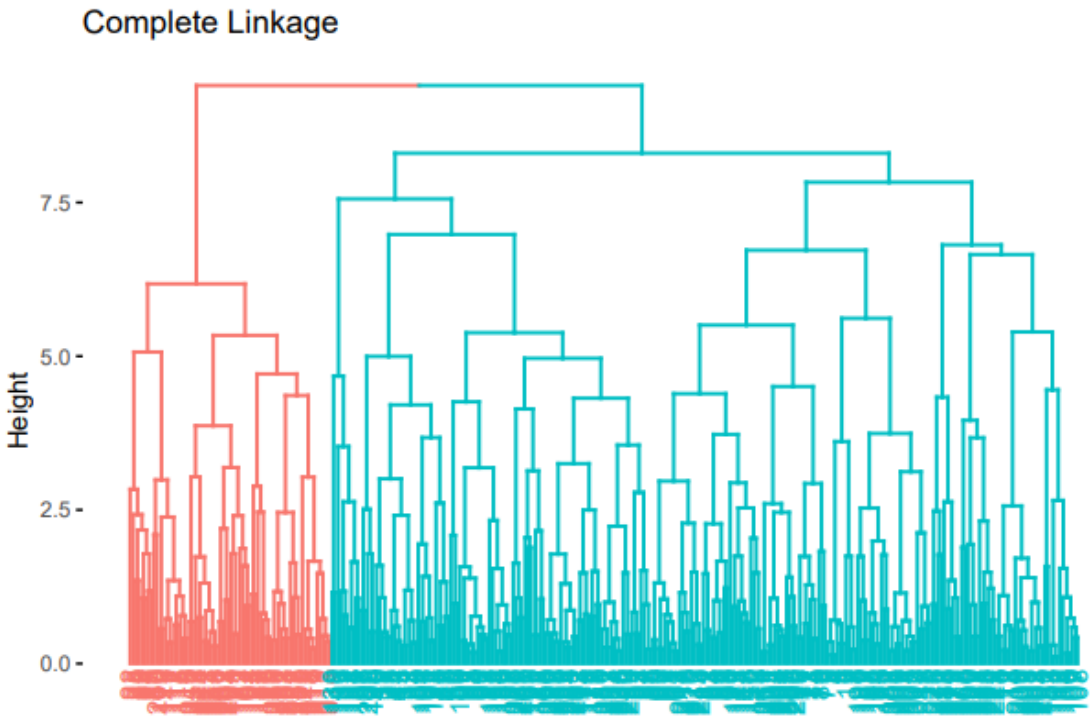


Figura 31. Dendograma con distancia manhattan y criterio Complete.

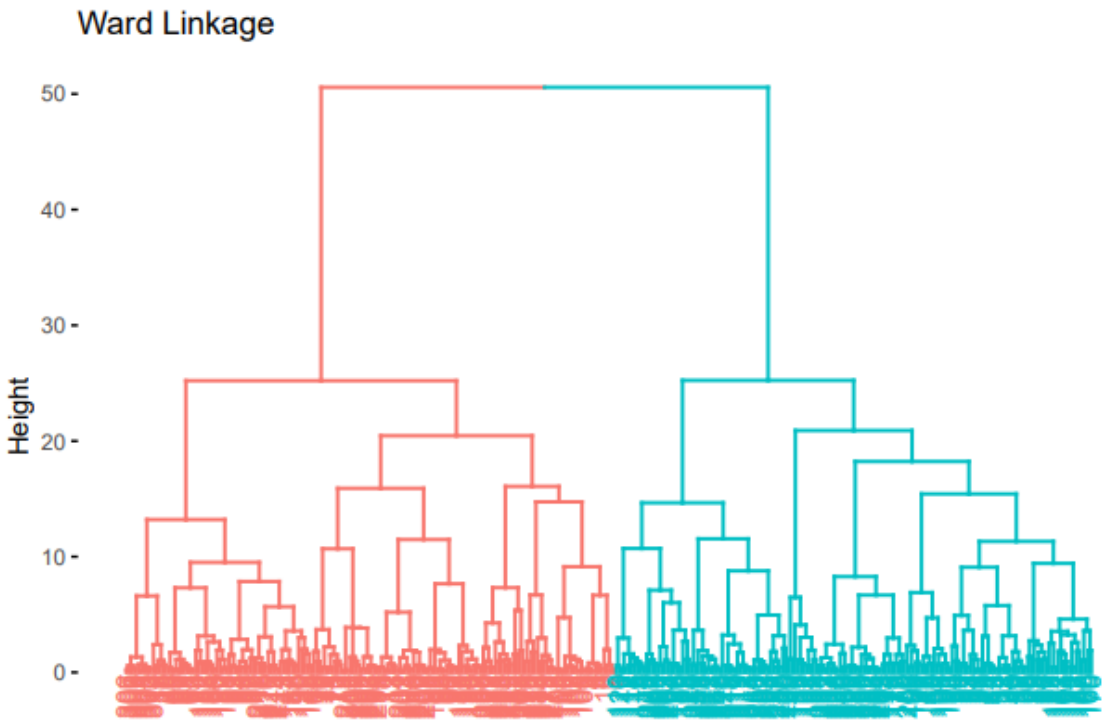


Figura 32. Dendograma con distancia manhattan y criterio Ward.

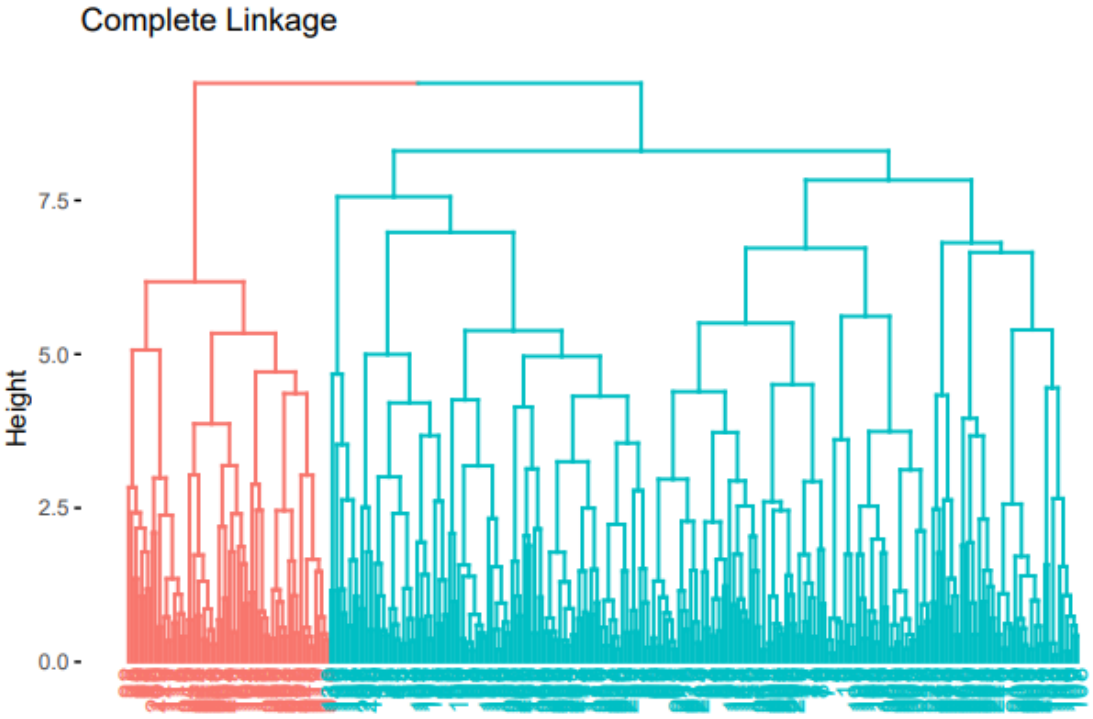


Figura 33. Dendograma con distancia correlada y criterio Complete.

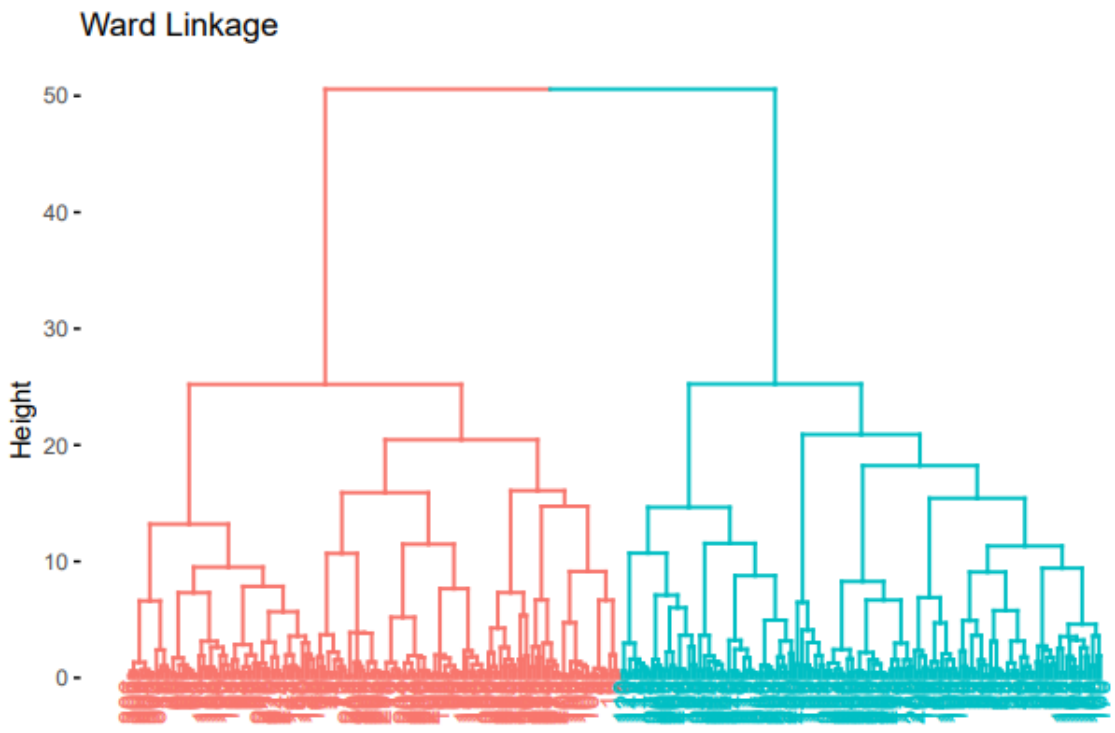


Figura 34. Dendograma con distancia correlada y criterio Ward.

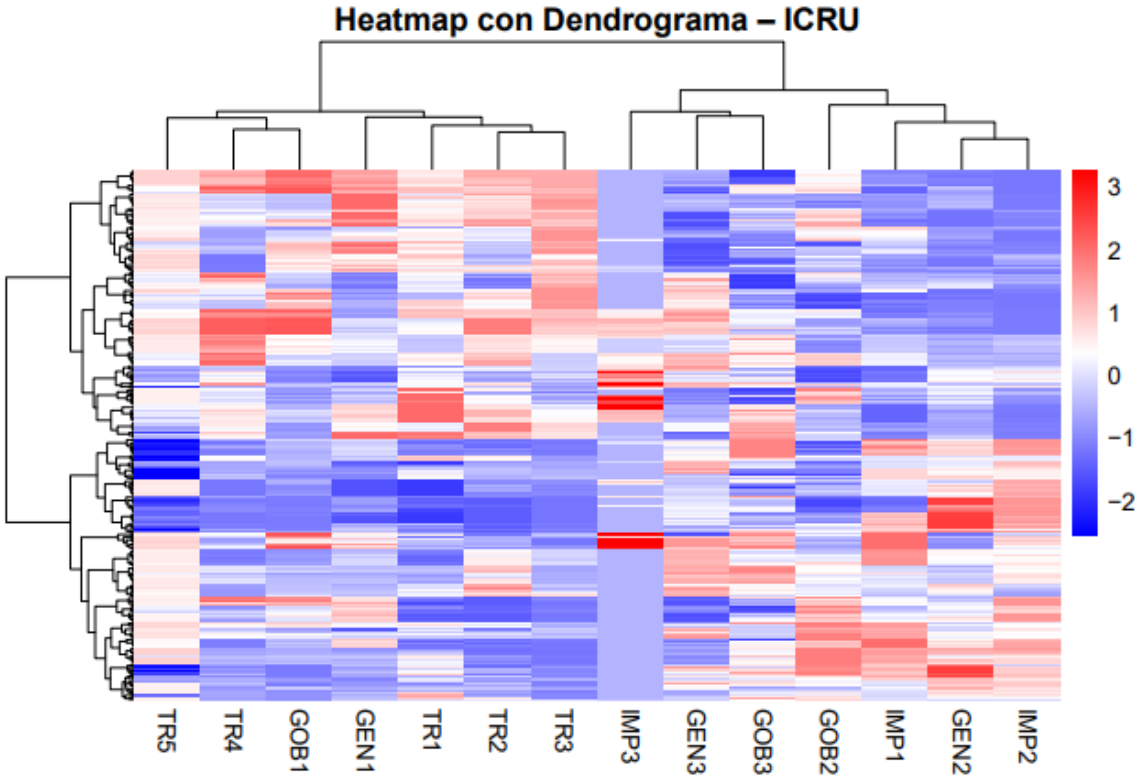


Figura 35. Mapa de calor con dendograma.

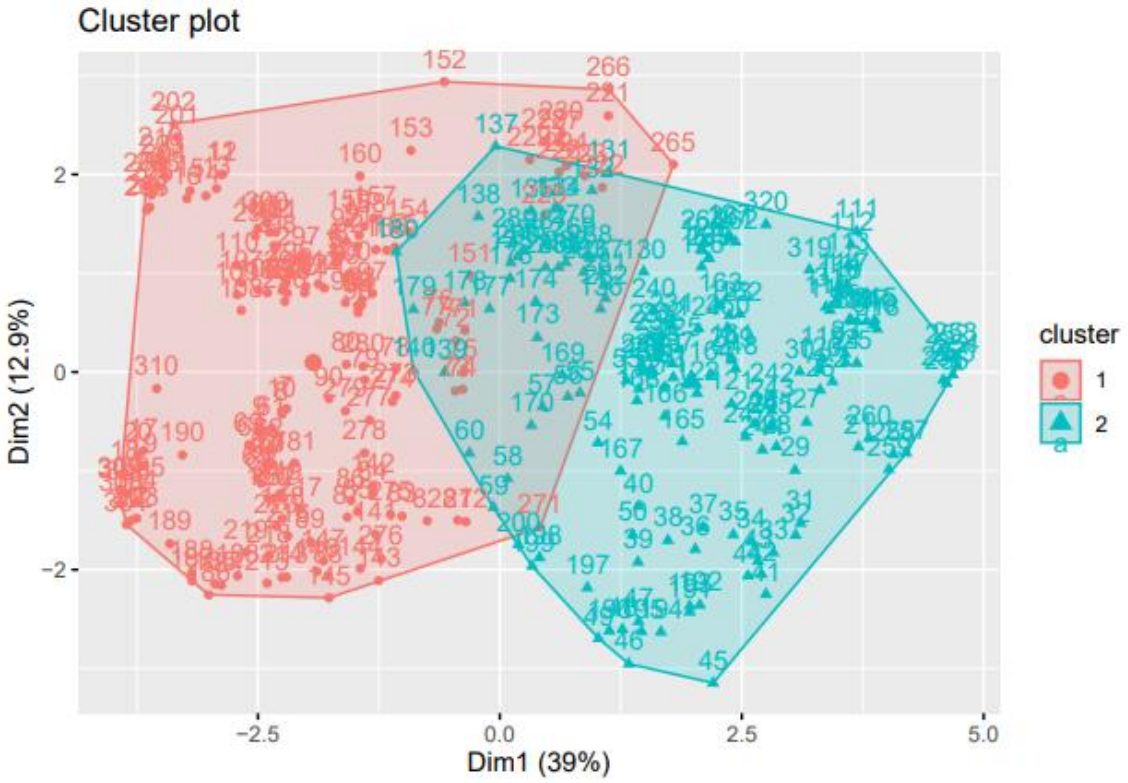


Figura 36. Plot de clústeres.

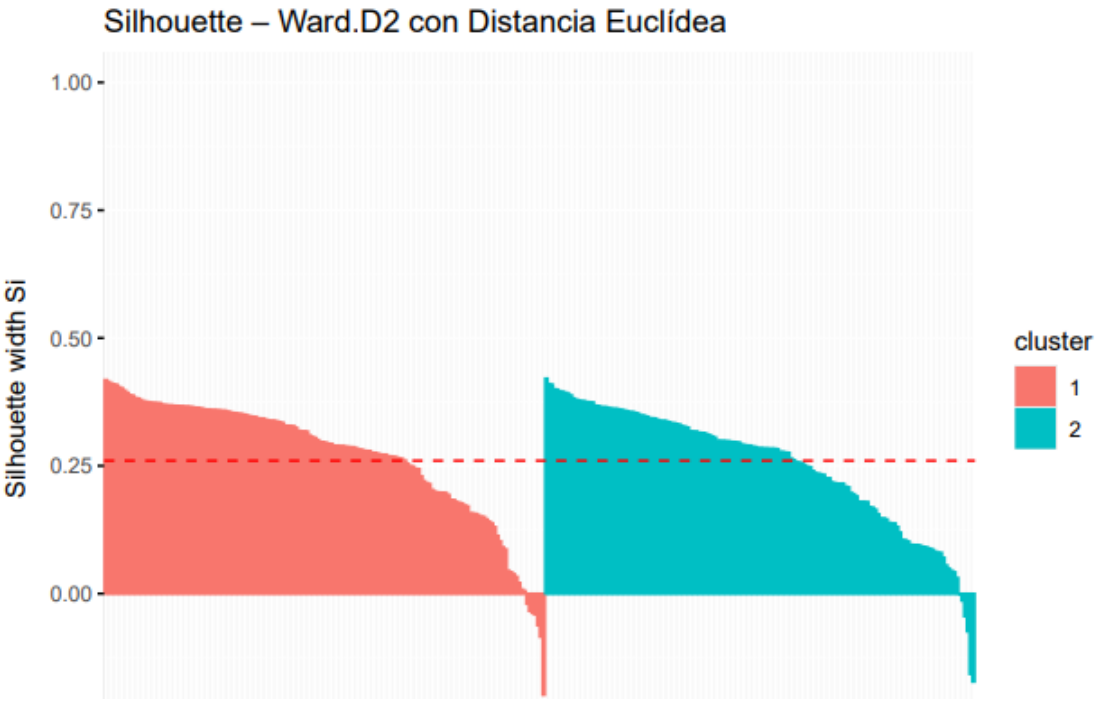


Figura 37. Análisis de Silhouette – Ward con distancia euclidiana.

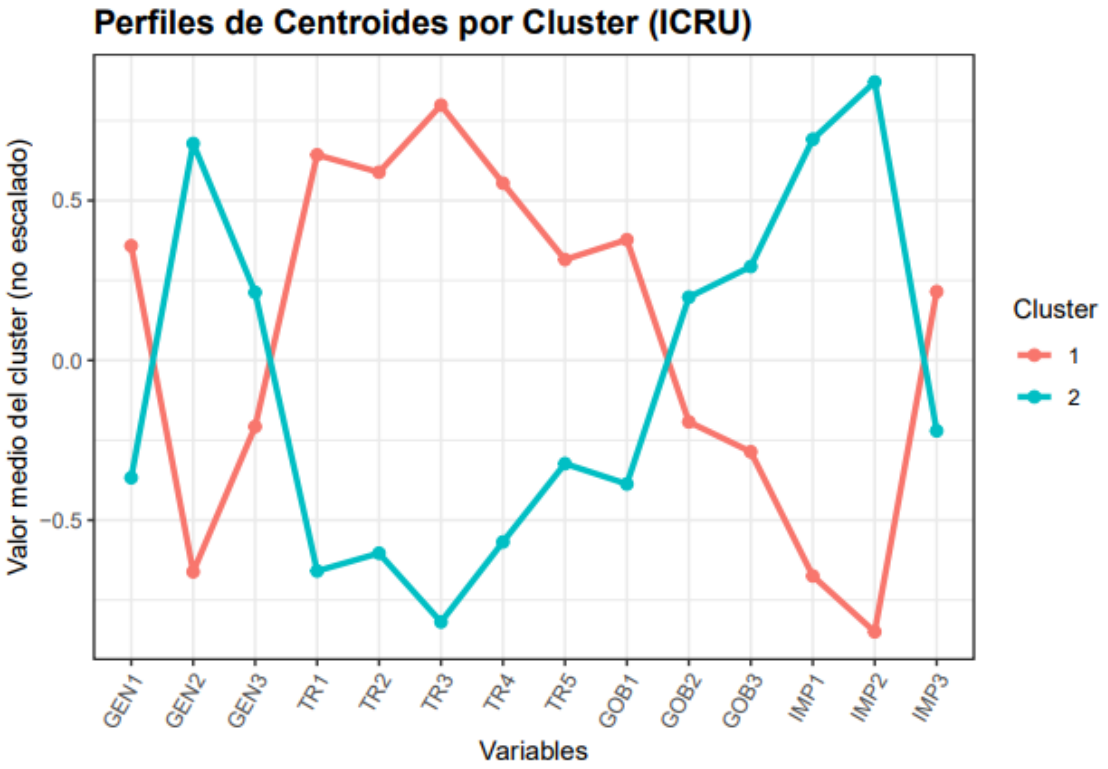


Figura 38. Centroides por cluster.

Indicador	Peso
GEN1	0,461
GEN2	0,252
GEN3	0,287

Tabla 13. Pesos de la dimensión de generación (ICRU).

Indicador	Peso
TR1	0,190
TR2	0,268
TR3	0,243
TR4	0,187
TR5	0,112

Tabla 14. Pesos de la dimensión de tratamiento (ICRU).

Indicador	Peso
GOB1	0,492
GOB2	0,006
GOB3	0,502

Tabla 15. Pesos de la dimensión de gobernanza (ICRU).

Indicador	Peso
IMP1	0,469
IMP2	0,488
IMP3	0,043

Tabla 16. Pesos de la dimensión de impacto (ICRU).

Indicador	Peso
GEN1	0,458
GEN2	0,177
GEN3	0,365

Tabla 17. Pesos de la dimensión de generación (ICRU 2023).

Indicador	Peso
TR1	0,201
TR2	0,282
TR3	0,259
TR4	0,132
TR5	0,126

Tabla 18. Pesos de la dimensión de tratamiento (ICRU 2023).

Indicador	Peso
INFRA1	0,500
INFRA2	0,500

Tabla 19. Pesos de la dimensión de infraestructura (ICRU 2023).

Indicador	Peso
GOB1	0,015
GOB2	0,455
GOB3	0,530

Tabla 20. Pesos de la dimensión de gobernanza (ICRU 2023).

Indicador	Peso
IMP1	0,486
IMP2	0,501
IMP3	0,013

Tabla 21. Pesos de la dimensión de impacto (ICRU 2023).

7.3 Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

Por la presente, yo, Gabriel Garbisu Martín, estudiante de E3-Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " Construcción de un Indicador de Circularidad de Residuos Urbanos en Europa (ICRU) ", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. Brainstorming de ideas de investigación: Utilizado para idear y esbozar posibles áreas de investigación.
2. Crítico: Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. Referencias: Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. Metodólogo: Para descubrir métodos aplicables a problemas específicos de investigación. Interpretador de código: Para realizar análisis de datos preliminares.
5. Corrector de estilo literario y de lenguaje: Para mejorar la calidad lingüística y estilística del texto.
6. Sintetizador y divulgador de libros complicados: Para resumir y comprender literatura compleja.
7. Revisor: Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 15 de Junio, 2026

Firma: *Gabriel Garbisu Martín*