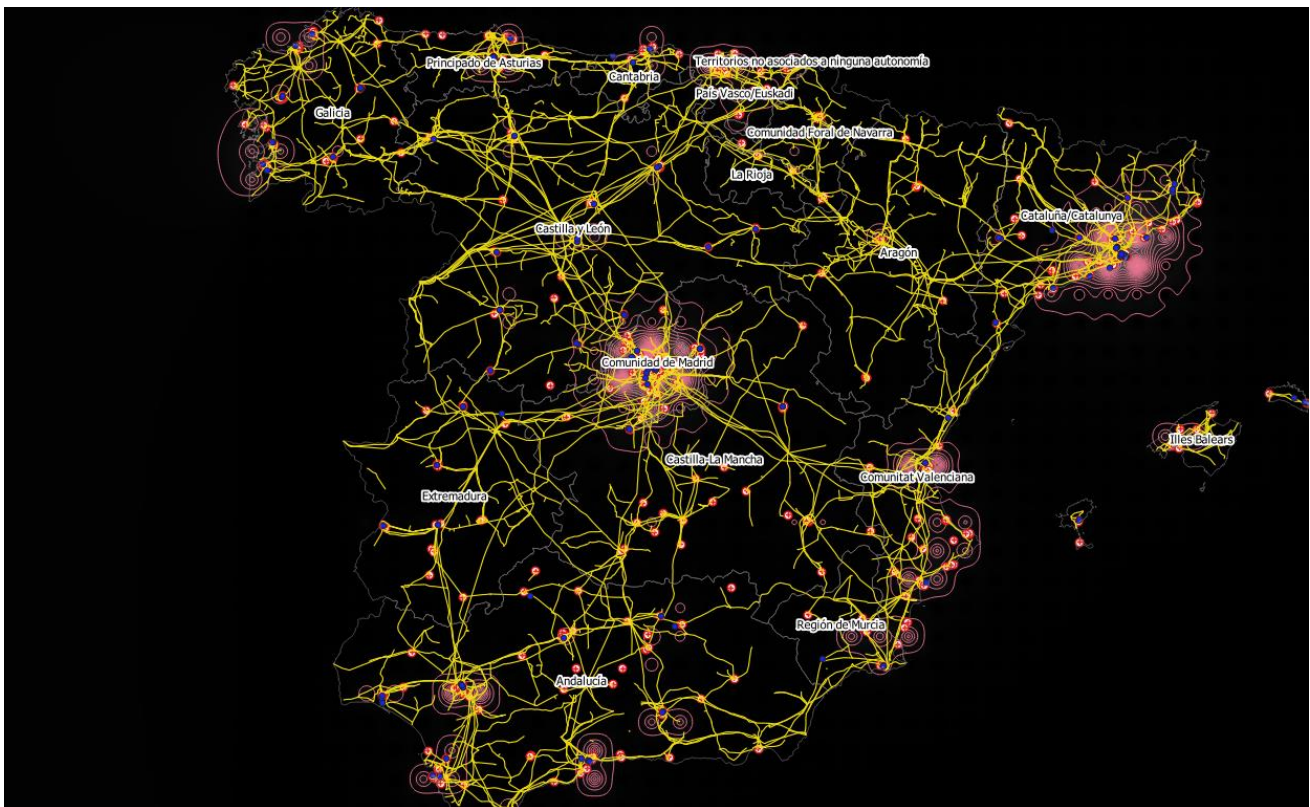

Applications of Geography in National Defense: Geospatial Analysis of the Security of Critical Infrastructures in Spain through Risk Scenarios

Aplicaciones de la geografía en la defensa nacional: Análisis Geoespacial de la Seguridad de Infraestructuras Críticas en España mediante Escenarios de riesgo.



Autor: Mario Laín de Pedro

Resumen

Este trabajo analiza las infraestructuras críticas en España, las cuales son denominadas críticas en los anexos de la directivas 2008/114/CE que posteriormente se implementan como leyes nacionales en todos los países que forman parte de la UE. El objetivo primordial es identificar las zonas más críticas a distintos ataques a infraestructuras críticas, se pretende determinar las áreas de España que serían más afectadas en términos de números de afectados en diferentes escenarios hipotéticos, como ataques terroristas, riesgos naturales, ataques cibernéticos, que podrían provocar cortes de luz, agua, incendios o radiación nuclear. Este proyecto se va a encargar de determinar cuáles deben ser priorizadas en términos de protección y resiliencia ante posibles amenazas externas. Utilizando Sistemas de Información Geográfica (SIG) y análisis espacial, se desarrolla una herramienta mediante un script en Python que avalúa combinaciones de diferentes infraestructuras críticas para localizar aquellas regiones de España con más riesgo de afectados. La metodología incluye la limpieza, carga y verificación de datos geoespaciales, la creación de una grilla para el análisis espacial, y el uso de técnicas de superposición geoespacial para identificar intersecciones entre infraestructuras y áreas pobladas. Las herramientas empleadas, incluyen bibliotecas de Python como GeoPandas dentro de la IDE de Jupyter Notebook, facilitado la manipulación y el análisis de grandes conjuntos de datos geoespaciales. Los resultados obtenidos identifican las combinaciones de infraestructuras que tienen el mayor impacto potencial en la población, permitiendo así priorizar su protección. Este análisis proporciona una base sólida para la planificación y gestión de infraestructuras críticas, ayudando a mejorar la resiliencia del país ante posibles amenazas.

Palabras clave: infraestructura crítica, análisis geoespacial, resiliencia, SIG, Python, GeoPandas.

Abstract

This work analyzes critical infrastructures in Spain, as designated in the Directive 2008/114/EC annexes and subsequently implemented as national laws in all EU member states. The primary objective is to identify the areas most vulnerable to various infrastructure attacks. The aim is to determine which regions in Spain would be most impacted in terms of the number of people affected under different hypothetical scenarios, such as terrorist attacks, natural disasters, or cyber-attacks, potentially leading to power outages, water supply disruptions, fires, or nuclear radiation. The project prioritizes areas for protection and resilience against potential external threats.

Using Geographic Information Systems (GIS) and spatial analysis, a tool developed through a Python script evaluates combinations of different critical infrastructures to identify regions in Spain with the highest risk of being affected. The methodology includes cleaning, loading, and verifying geospatial data, creating a grid for spatial analysis, and employing geospatial overlay techniques to identify

intersections between infrastructures and populated areas. Tools such as GeoPandas and Jupyter Notebooks facilitate the manipulation and analysis of large geospatial datasets.

The results highlight combinations of infrastructures with the highest potential impact on the population, allowing for the prioritization of their protection. This analysis provides a solid foundation for the planning and management of critical infrastructures, enhancing the country's resilience to potential threats. Keywords: critical infrastructure, geospatial analysis, resilience, GIS, Python, GeoPandas.

Keywords: critical infrastructure, geospatial analysis, resilience, GIS, Python, GeoPandas.

1. Introducción

1.1. Marco Geopolítico y su influencia en la Protección de Infraestructuras críticas

El contexto geopolítico en este 2024 es extremadamente complejo, marcado por múltiples tensiones y desafíos que afectan a la seguridad global y nacional de multitud de países incluyendo España. En el mundo actual, la competencia entre estas grandes naciones (Estados Unidos, China sin olvidarnos de Rusia), las cuales dominan el escenario global, mientras otros países como India, Arabia Saudita, Turquía, Sudáfrica y Brasil emergen como actores clave sin alinearse de momento completamente con ningún bloque.

Europa se encuentra en una situación geopolítica crítica, no vista desde la Guerra Fría. La guerra en Ucrania ha intensificado las tensiones geopolíticas entre todos los Estados europeos y Rusia. Este conflicto ha hecho replantear a los estados europeos la importancia de la resiliencia de las infraestructuras críticas, tanto en términos de defensa como de estabilidad económica y social debido a que lo primero que es atacado en una guerra son infraestructuras críticas como se ha comprobado en la guerra de Ucrania. Donde Rusia ha atacado una gran variedad de infraestructuras críticas para debilitar las capacidades del país y afectar a la defensa como a su economía y a la población civil. Algunas de las infraestructuras han sido (energéticas, transportes, agua, sanitarias, almacenamiento de combustible y cibernética) o infraestructuras críticas esenciales como las generadoras de energía eléctrica, ataques con drones a la central nuclear de Zaporizhia, la más grande de Europa. La red eléctrica ha sido uno de los objetivos más frecuentes. Los ataques con misiles y drones han causado cortes de energía especialmente en los meses de invierno

España, como miembro de la Unión Europea y de la OTAN, se ve afectada por estas dinámicas geopolíticas globales y regionales. Enfrenta desafíos específicos dentro de su nación, como son el separatismo en Cataluña y País Vasco además de una asfixiante inmigración desde África, que agravan su contexto geopolítico. La seguridad de las infraestructuras críticas en España no solo depende de las dinámicas internas sino también de las fuerzas geopolíticas externas que se dan en cada momento de la historia. La ubicación de España en el cruce de rutas estratégicas marítimas y terrestres la convierte en un punto vital para la seguridad europea debido a las inestabilidades en el Norte de África, junto con las tensiones en el Mediterráneo Oriental.

España vive en la actualidad en un contexto estratégico definido por la volatilidad global y regional, la emergencia de nuevos desafíos a la seguridad y el impacto de las crisis económicas. Estos factores resultan determinantes para definir su política de seguridad nacional. (Miranzo y Río, 2014) En los próximos años, el Estado español podría tener que participar en distintos conflictos armados en los que

el papel de las fuerzas armadas resulte crucial para mantener nuestro sistema de valores culturales, territoriales, económicos, así como para proteger a los ciudadanos y los intereses españoles.

El punto de inflexión, donde cambia el paradigma de la seguridad de las infraestructuras críticas en todos los niveles son los atentados terroristas del 11 de Septiembre de 2001 sobre el World Trade Center. Con este suceso se inicia un cambio de paradigma, llevando a un aumento drástico en las medidas de seguridad sobre infraestructuras críticas a nivel mundial. Otro acontecimiento terrorífico pocos años después y el que cambia la ruta de la UE en los temas de protección de infraestructuras críticas son los atentados del 11 de Marzo de 2004 en Madrid, conocido como 11M, en cuatro trenes de la red de cercanías de la comunidad de Madrid. Resultando en 193 muertos y alrededor de dos mil heridos, convirtiéndose en el segundo mayor ataque terrorista en la historia reciente de la Unión Europea. (EU Terrorism Situation and Trend Report, 2004).

Otros casos fueron menos retrasmitado por las televisiones y radios nacionales pero no son menos importantes porque da comienzo una nueva forma de atacar desde la distancia a infraestructuras críticas nacionales. En 2007 en Estonia comienza el primero de muchos ciberataques que se sucedieron después contra infraestructuras críticas. Estonia, uno de los países más digitalizados del mundo y más preparados para repeler ataque de este tipo, sufrió un ciberataque contra distintas agencias gubernamentales, la policía, el primer banco del país y varios medios de comunicación, que desembocaron en una crisis nacional con pérdidas económicas significativas. (Miranzo y Río, 2014). Este incidente subrayó la importancia de la ciberseguridad en la protección de las infraestructuras críticas en el marco de la UE. A partir de estos ataques terroristas a infraestructuras críticas la UE cambia su concepción de la defensa de los estados. En consonancia, primero propone comunicados que posteriormente se convertirán en normativas y directivas para la seguridad de todas las infraestructuras críticas de la UE. Además cambia la forma de cooperar entre los diversos países para que la defensa ante amenazas se realice de manera conjunta con todo tipo de herramientas y programas que se irán implementando con los años. Pero sobre todo con el principio estrella de la UE que es la cooperación entre los estados europeos.

1.2. Dando mayor relevancia sobre protección y resiliencia de infraestructuras críticas.

En un mundo cada vez más digitalizado, la ciberseguridad de nuestras infraestructuras críticas se vuelve de mayor importancia. Las filtraciones de Snowden y el gran agujero de seguridad, denominado “The Heartbleed Bug” han puesto de manifiesto las vulnerabilidades del ciberespacio y las telecomunicaciones. (Durumeric, Ma, & Bailey, 2014). El denominado “The Heartbleed Bug”, afecta a dos tercios de internet, debido a un fallo en algunas versiones del código de programación OpenSSL, utilizado por bancos, agencias de información y proveedores de diferentes servicios electrónicos entre otros, comprometiendo información sensible de millones de usuarios.

El incremento continuo de riesgos y amenazas no tradicionales, especialmente el terrorismo internacional y los ciberataques, ha tenido como objetivos principales tanto a los individuos como a las infraestructuras críticas. Estos ataques incrementan la vulnerabilidad de Estados y empresas privadas causando graves daños al funcionamiento de la sociedad (ENISA, 2018). A causa del sistema hipertecnológico en el que vivimos, con una alta demanda de determinados servicios, y sistemas tecnológicos para el normal funcionamiento de los estados. Las sociedades modernas dependen de infraestructuras críticas cuya interrupción tendría un grave impacto en la salud, la seguridad, la energía y el bienestar económico de los ciudadanos. Por lo tanto, la protección de estas infraestructuras y sistemas se ha convertido en una prioridad para la mayoría de Estados de mundo.

Dentro de los conflictos armados que pueden llegar a sucederse, una de las principales tendencias radica en las capacidades militares de diferentes Estados en diversos ámbitos: terrestre, aéreo, naval, espacial y del ciberespacio (Smith & Jones, 2019). Estas amenazas son promovidas por actores estatales como no estatales, con el objetivo de movilizar la opinión pública y la desestabilización política, económica y social incluso medioambiental de un país. Debido a los focos de inestabilidad actuales en determinados entornos internacionales y a la existencia de Estados débiles y corruptos, surgen grupos violentos y armados, los cuales pueden actuar para debilitar a otros Estados. Estos grupos buscan provocar pérdidas humanas y económicas atacando las principales infraestructuras críticas de los países, con el fin de paralizar sus sistemas o entorpecer sus servicios básicos. (Johnson, 2020).

España está expuesta a una gran variedad de amenazas, a las cuales debemos responder para garantizar una mayor seguridad de los ciudadanos, las instituciones e infraestructuras críticas. Estas infraestructuras son esenciales para el normal funcionamiento del sistema que hemos creado alrededor de ellas. La protección y resiliencia de estas infraestructuras son, por tanto, prioridades estratégicas para el Estado español (García, 2017). Los vínculos establecidos a través de tratados con nuestros aliados europeos, como gran ejemplo los tratados firmados con la OTAN, pueden provocar la adhesión a distintos conflictos debido a las relaciones bilaterales estratégicas, conflictos en los que no tenemos ningún interés y solo causarían pérdidas humanas y la destrucción de la Europa que conocemos. El tratado del Atlántico Norte establece obligaciones para los 28 miembros de la Alianza; según el artículo 5, un ataque armado contra alguno de ellos será considerado como ataque contra todos (OTAN, 2022).

1.3. Objetivos del proyecto.

El objetivo principal al cual se busca dar respuesta en este trabajo final de máster es la identificación de regiones críticas en distintos escenarios hipotéticos de ataques a infraestructuras críticas dentro del territorio español. Se determinarán las áreas españolas que presentan un mayor riesgo en términos de afectados en diferentes escenarios regionales. El proyecto se enfoca en determinar donde se encuentran estas áreas para posteriormente poder priorizar en términos de protección y resiliencia ante posibles

amenazas. Se me ocurren varias preguntas interesantes que podrían resolverse con los resultados obtenidos en este proyecto: ¿Serán las zonas donde mayor acumulación de población presenta España como son todas las zonas costeras y las grandes ciudades en las que mayores riesgos obtendremos? ¿Serán las regiones de la España vaciada aquellas más seguras y con menor número de afectados? ¿Será de suma importancia la proyección de las centrales nucleares para no obtener tasas elevadas de afectados en España? ¿Sera esto debido a que las infraestructuras críticas se aglomeran en las grandes ciudades dejando a las zonas interiores de España con menor número de ellas? ¿Puede ser que cambiando la ubicación de ciertas infraestructuras críticas y colocándolas en áreas con baja densidad de población en áreas de la España vaciada se redujese el riesgo en las en estas zonas densamente pobladas? ¿Es bueno el hábitat concentrado de las ciudades para estos determinados ataques en infraestructuras críticas?

Otro de los objetivos principales será si con el lenguaje de programación de Python se podrá desarrollar un script que se encargue de crear las combinaciones de infraestructuras más letales, de desarrollar a la vez ciertos análisis geoespaciales dentro del código y evalúe las zonas de España con mayor riesgo debido a la acumulación de infraestructuras críticas y de personas que viven en esas áreas.

Objetivos específicos:

1. Construcción de escenarios realistas de amenazas.

- Hipótesis: Las infraestructuras críticas en España enfrentan diversas amenazas y vulnerabilidades que pueden comprometer su seguridad y la de la población de su entorno, sin embargo, lo que se plantea es que es posible que esto no tenga una distribución espacial homogénea en todo el territorio, es decir, que no todo el país esté expuesto a los mismos niveles de riesgo. Se evaluará el impacto de diferentes escenarios en la población y las infraestructuras.
- Elementos a analizar: Los tipos de amenazas que podrían ocurrir son terroristas, ciberataques a centrales nucleares, caída de la red eléctrica, ataque a centros militares u educativos, o cortes en la red de transportes y como todas ellas afectarían a la población.
- Factores a considerar: Población afectada en número de personas, el tipo de infraestructura, el impacto potencial mediante la visualización en mapas de calor mediante `idw`
- Técnicas: Análisis cartográfico en base a escenarios de riesgo de ataque que contemplen las regiones de España con mayor número de afectados para posteriormente mejorar la preparación y la capacidad de respuesta de estas infraestructuras ante posibles incidentes. La generación de escenarios y simulaciones se han hecho mediante un script de Python y sus múltiples librerías como son `GeoPandas`, `Numpy`, `Folium`... que se ha desarrollado específicamente para ello en este trabajo

2. Marco teórico

2.2. La geografía como herramienta para la defensa nacional.

Una frase que guía la filosofía de este proyecto es: “El peor enemigo es el que no amenaza, porque sorprende y no ofrece la oportunidad de preparar la defensa.”. Esta cita anónima resalta la importancia de la preparación y la previsión en la defensa de infraestructuras críticas. A través de la anticipación de posibles amenazas y la planificación adecuada, es posible mejorar significativamente la seguridad y resiliencia de estas infraestructuras frente a eventos imprevistos. (Smith & Brooks, 2013).

Un libro muy interesante es “La Geografía: un arma para la guerra” de Yves Lacoste, publicado en 1976 es una obra que transformó la manera en que se percibe y se utiliza la geografía. Lacoste argumenta dentro de este libro que la geografía no es solo una disciplina académica, sino que tiene aplicaciones prácticas y estratégicas particularmente en el contexto de la guerra, la defensa de elementos de interés y la dominación política. Además el tema a tratar en este trabajo que es como la distribución de las infraestructuras críticas en una nación no solo debe de ser vista desde una perspectiva de eficiencia y accesibilidad, sino desde un ángulo estratégico y de seguridad nacional en el cual si intente proteger a la población circundante de estas infraestructuras críticas. Mediante el análisis geográfico se pueden revelar vulnerabilidades en las infraestructuras críticas nacionales que pueden ser explotadas en tiempos de conflictos que es lo que vamos a tratar de averiguar con el proyecto final de máster. La planificación y protección de estas infraestructuras críticas deben incluir una comprensión profunda de la geografía como herramienta estratégica, para prever y mitigar posibles ataques a lugares de importancia máxima o desastres naturales que pueden ser utilizados como pretextos para acciones malvadas contra una nación.

La geografía ha sido una ciencia fundamental desde los tiempos antiguos, proporcionando a las civilizaciones una comprensión profunda de su entorno. Esto ha influido en la planificación y ejecución de estrategias militares así como en la administración de recursos y la formación de sociedades. Sin embargo, en tiempos modernos, la geografía ha sido a menudo infravalorada en comparación con otras disciplinas como la ingeniería y la informática (Robinson, 2016). Esta desvalorización ha llevado a una falta de apreciación de su importancia crítica en la defensa y seguridad de las infraestructuras críticas.

2.2.1. Importancia histórica de la geografía en las guerras. Ejemplos concretos.

Desde la antigüedad, la geografía ha desempeñado un papel crucial en la defensa y en las estrategias militares. El conocimiento del terreno, el clima y los recursos ha sido vital para la supervivencia y el éxito en conflictos bélicos. Civilizaciones antiguas como la China imperial y los imperios europeos

utilizaron los conocimientos geográficos para la construcción de fortificaciones y la planificación de campañas militares.

La Gran Muralla China: Un claro ejemplo del ingenio geográfico.

La Gran Muralla China es uno de los ejemplos más icónicos de la utilización del conocimiento geográfico para la defensa. Esta estructura monumental, una infraestructura crítica que en sus tiempo, que se extiende a lo largo de más de 21,000 kilómetros, no solo actuaba como una barrera física contra los invasores, sino que también aprovechaba las características geográficas naturales para reforzar su defensa. (Fairbank, J. K., & Goldman, M. 2006).



Figura 1. Gran muralla de China

Castillos Medievales en Europa: Aprovechando el Terreno.

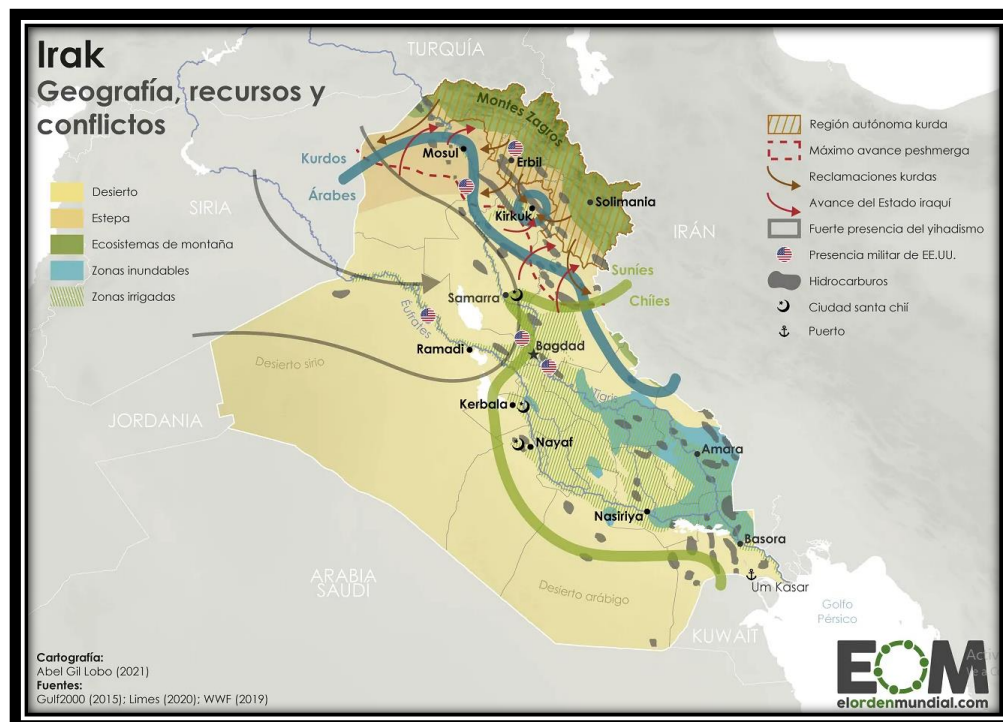
En la Europa medieval, los castillos se erigían en colinas y puntos elevados estratégicos. Estas ubicaciones permitían a los defensores tener una vista panorámica del entorno, facilitando la detección temprana de los invasores y ofreciendo ventajas defensivas. Las elevaciones y los obstáculos naturales como ríos y bosques se utilizaron para fortalecer las posiciones defensivas. Las elevaciones y los obstáculos naturales como ríos y bosques se integraban en las defensas del castillo, creando un sistema fortificado que aprovechaba al máximo el terreno. Pounds, N. J. G. (1994). *The Medieval Castle in England and Wales: A Social and Political History*.



Figura 2. Castillo Medieval

La guerra de Corea y Vietnam: Terrenos desafiantes.

Durante la Guerra de Corea, el terreno montañoso y las extremas condiciones climáticas jugaron un papel crucial en la planificación y ejecución como puntos estratégicos de control (Ambrose, 1994). En la guerra de Vietnam, el conocimiento del denso terreno selvático y los complicados sistemas de túneles utilizados por el Viet Cong subrayaron la importancia de la geografía en las tácticas de guerrilla y la guerra asimétrica. (Westheider, 2007).



Fuente: Abel Gil (2021).

Figura 3. Mapa guerra de Irak

2.2.2. La geografía en la planificación militar moderna.

En la era moderna, la geografía sigue siendo esencial para la planificación y la defensa nacional de nuestras infraestructuras críticas, las aplicaciones son variadas (figura 4). Como ejemplo de infraestructuras críticas importantes para la seguridad son las bases militares, la logística de suministros y el despliegue de tropas dependen en gran medida de un análisis geográfico detallado con tecnologías GIS mezcladas con programación como las que vamos a utilizar en nuestro estudio. Las bases aéreas y navales se sitúan estratégicamente en unos determinados lugares del planeta para maximizar la capacidad de respuesta rápida a amenazas. Por ejemplo, las bases militares de los Estados Unidos están dispersas estratégicamente alrededor del mundo para asegurar una respuesta rápida a emergencias globales. Collins, J. M. (1998).



Fuente. Elaboración propia

Figura 4. Organigrama de planificación geográfica de bases militares

La geografía afecta directamente a la logística militar además de a las rutas de suministro para evitar terrenos difíciles y minimizar la exposición a amenazas. Durante la Guerra de Afganistán, el terreno montañoso y las difíciles condiciones climáticas jugaron un papel crucial en las tácticas de guerrilla utilizadas por los combatientes talibanes. (Grau & Gress, 2002). En contraste, en los conflictos en el Medio Oriente, los vastos desiertos han influido en las estrategias militares, afectando tanto el movimiento de tropas como la logística de suministros. (Pollack, 2002).

En la era moderna, las innovaciones tecnológicas han transformado la manera en que se integra la geografía en la planificación estratégica de las infraestructuras críticas militares. Los sistemas de información geográfica y la teledetección proporcionan datos precisos y en tiempo real que son

cruciales para la toma de decisiones. (Batty & Longley, 1994; DeMers, 2009; Goodchild & Janelle, 2004).

Los sistemas de Información Geográfica (SIG de ahora en adelante) son utilizados para mapear y analizar datos geoespaciales, permiten la creación de modelos detallados del terreno, identificando áreas de importancia estratégica y planificando rutas de movimientos y suministros. (DeMers, 2009). La teledetección por satélite proporciona imágenes y datos en tiempo real, esenciales para monitorear movimientos de tropas, detectar amenazas y evaluar daños en infraestructuras críticas en tiempos de guerra.

2.2.3. El valor de la geografía


La desvalorización de la geografía en la era moderna puede atribuirse a varias razones interrelacionadas, que van desde cambios en la percepción académica y profesional hasta avances tecnológicos que han redefinido las prioridades en la educación. El avance de las tecnologías, particularmente en el ámbito de la informática y la ingeniería, ha desplazado la atención y los recursos hacia estas áreas. Además la capacidad de solucionar problemas complejos ha hecho que estas áreas sean percibidas como más avanzadas y relevantes.

A menudo se percibe a la geografía como una ciencia descriptiva, centrada en la mera representación de lugares y paisajes sin ofrecer soluciones prácticas inmediatas. Esta percepción limita la comprensión del potencial analítico y predictivo de la geografía, especialmente en la integración de datos espaciales y temporales para resolver problemas complejos. La falta de comprensión del valor analítico de la geografía ha contribuido a su desvalorización. En muchos sistemas educativos, los programas de geografía han sido reducidos o incluso eliminados en favor de disciplinas que se consideran más vinculadas al mercado laboral, como la informática, la ingeniería y las ciencias empresariales.

La falta de colaboración interdisciplinaria entre geógrafos y profesionales de otras áreas también ha contribuido a la desvalorización de la geografía. Mientras que la ingeniería y la informática a menudo trabajan de la mano en proyectos complejos, la geografía a menudo se queda relegada a un segundo plano. La integración de conocimientos geográficos con otros campos puede proporcionar soluciones más efectivas a problemas complejos.

En la planificación urbana y regional, la geografía a menudo es subestimada en comparación con la ingeniería civil y la arquitectura. Los planificadores urbanos pueden pasar por alto los factores críticos como la topografía, los patrones climáticos y los riesgos naturales, lo que puede llevar a una planificación deficiente y vulnerabilidades en nuestras infraestructuras. La falta de consideración de los factores geográficos puede resultar en problemas como inundaciones, deslizamientos de tierra y otros desastres naturales que podrían haberse mitigado con análisis geográficos adecuados.

Las prioridades políticas y económicas también juegan un papel crucial en la desvalorización de la geografía. Los gobiernos y las instituciones financieras a menudo priorizan las inversiones en áreas que prometen retornos económicos rápidos, como la tecnología y la industria, dejando de lado la geografía que se percibe como una ciencia de menor impacto inmediato. Esta tendencia de inversión ha llevado a una menor financiación para la investigación y la educación en geografía, perpetuando aún más su desvalorización como se aprecia en la figura 5 donde se muestra el descenso de los matriculados en los últimos catorce años.



Fuente: Ministerio de Educación Gobierno de España.

Figura 5. Gráfico reducción número de titulados en geografía últimos en 14 años

2.2.4. Repercusiones de la desvalorización de la geografía en nuestros días.

La desvalorización de la geografía tiene varias repercusiones en múltiples áreas, incluyendo la defensa, la seguridad, la planificación urbana todas ellas vinculadas con la seguridad de las infraestructuras críticas. Una comprensión limitada del terreno y los factores geográficos pueden resultar en la elección de ubicaciones inadecuadas para todo tipo de infraestructuras crítica, lo que puede comprometer la operativa y la seguridad de las infraestructuras y de la gente que convive con ellas. Además, sin un análisis geográfico adecuado, es difícil prever y mitigar los riesgos naturales, sociales y las amenazas ambientales que podrían afectar a estas infraestructuras críticas. La falta de consideración de los factores geográficos críticos en la ubicación de infraestructuras puede resultar en inundaciones, deslizamientos de tierras y otros desastres que podrían haberse evitado con la planificación geográfica

adecuada. Esto no solo pone en riesgo vidas y propiedades, sino que también puede resultar en costos económicos significativos debido a daños y reconstrucciones.

En este punto viene bien volver a hablar del libro de Yves Lacoste en el cual el autor distingue entre la geografía académica, la geografía espectáculo y la geografía como herramienta de poder. La primera es la que enseñan en las escuelas, institutos de todo el mundo y es una de las razones por la cual se ha desvalorizado a la geografía de esta manera ya que desconecta a la ciencia de aplicaciones prácticas. La segunda es utilizada en medios de comunicación y entretenimiento y la tercera que es la verdadera geografía es la que utilizan estados para estrategias de dominación.

La geografía se convierte en una ciencia muy valorada y poderosa en manos de estados. Pero Lacoste critica duramente a la geografía académica por su falta de relevancia práctica y su desconexión de las realidades estratégicas y políticas. Señalando que esta forma de enseñar la geografía perpetúa una visión limitada y poco crítica del mundo, que beneficia a las élites y despoja a la población general de un entendimiento profundo y útil del espacio.

1.1.3. Revalorización de la Geografía.

Es fundamental revalorizar la geografía y reconocer su papel central en la defensa y la seguridad nacional de nuestras infraestructuras y de nuestro país. Además debe de servir para entender y cuestionar las estructuras de poder, en lugar de simplemente describir el mundo de manera desinteresada. La geografía proporciona el contexto necesario para comprender las amenazas y vulnerabilidades de una región, permitiendo a los planificadores localizar las infraestructuras críticas en regiones apropiadas para el desarrollo de dichas actividades. Un ejemplo podría ser la localización de estaciones de tren importantes pongamos como ejemplo Atocha, cercanas a importantes comisarias. La integración de tecnologías avanzadas como los Sistemas de Información Geográfica (SIG), la programación y la teledetección pueden proporcionar las herramientas necesarias para utilizar grandes cantidades de datos en análisis precisos, cruzando esta información de manera inteligente y fortaleciendo así aún más la capacidad de defensa nacional.

2.3. El concepto de amenaza es vital para la defensa.

El concepto de amenaza, desde el punto de vista etimológico, deriva del latín minacia. Esta palabra tiene varios significados:

Palabra o gesto intimidatorio.

Promesa de castigo.

Indicio de cosa desagradable o terrible, de desgracia, de enfermedad.

Según estas definiciones, la amenaza no es la propia desgracia, el castigo o el daño, sino su anuncio. No es la amenaza la que provoca el temor, sino quien lo anuncia. Nuestros enemigos no constituyen un peligro por sí mismo, sino que los identificamos como tal debido a su actitud amenazadora. Con esta actitud, el enemigo puede pretender intimidar, insinuando lo que nos podría acontecer si no nos sometemos a su voluntad, aunque no nos haya causado daño directo. Es esta actitud intimidadora, en sí misma la que produce la amenaza. Aunque la amenaza es solo una señal o percepción, puede contribuir para desestabilizar una defensa al provocar temor o inseguridad. La amenaza representa, una percepción, aquello que nos preocupa e intimida. (Saint Pierre, Raza, Fuenzalida, 2014).

La estrategia española de seguridad define una amenaza como cualquier circunstancia o agente que ponga en peligro la seguridad o estabilidad de España. El riesgo es la contingencia o probabilidad de que una amenaza se materialice produciendo daños (Estrategia de Seguridad Española, 2013).

Un ejemplo sería la posesión de armas nucleares por parte de algunos Estados, puede constituir una amenaza para los países vecinos. Sin embargo para los poseedores es percibida como una garantía para su seguridad. En un futuro cercano el cual no se parecerá en nada al pasado, acontecimientos nuevos e inesperados seguirán ocurriendo y definirán nuestro contexto de seguridad.

2.3.1. Los ámbitos de las amenazas.

El conocimiento de los intereses vitales y estratégicos de España, así como el análisis de las amenazas y riesgos existentes, constituyen los cimientos sobre los que se formulan las directrices, directivas, leyes y líneas estratégicas necesarias para fortalecer la seguridad de nuestras infraestructuras además de su población circundante.

Todas las amenazas para la seguridad del estado español tienen lugar en unos determinados ámbitos, que es necesario examinar debido a que todas las infraestructuras críticas de este trabajo van a estar en alguno de estos ámbitos. La estrategia española de seguridad describe seis ámbitos de amenaza:

Terrestre:

Este ámbito es fundamental debido al uso intensivo que le dan los ciudadanos, por habitar y desarrollar la totalidad de sus vidas y actividades en él. Incluye todo el espacio del territorio nacional y aquellos espacios donde los intereses españoles estén presentes y puedan surgir amenazas que afecten directamente a España. En este ámbito entrarían la gran mayoría de infraestructuras críticas con las cuales vamos a trabajar en este proyecto porque son elementos que interactúan con el espacio terrestre y las poblaciones como son todas las infraestructuras críticas relacionadas con la producción de energía, los transportes, la salud, el agua y la educación.

Marítimo:

España posee aproximadamente 8000 kilómetros de costas, diferenciándose cuatro dominios marinos Mediterráneo, Cantábrico, Atlántico peninsular y Atlántico macaronésico (Canarias). Además, el 90% de las importaciones y el 65% de las exportaciones se realizan a través de nuestros puertos que es otra de las infraestructuras críticas más importantes que tiene el territorio español y las cuales vamos a utilizar en nuestro análisis, por lo que la protección en el ámbito marítimo es crucial. La vigilancia y seguridad en el medio marítimo deben abordarse mediante la integración eficiente de medios civiles y la protección adecuada de dichas infraestructuras.

Aéreo:

El espacio aéreo es otro de los ámbitos de máxima importancia a la hora de darle seguridad a un estado a causa del aumento del tráfico aéreo en las últimas décadas. Todas estas infraestructuras críticas como los aeropuertos se les deben de dotar de una protección mayor debido a que siempre hay grandes aglomeraciones de personas y pueden ser lugares apropiados para ataques terroristas como se vio en el caso de Belgica donde varios asaltantes causaron el terror en el aeropuerto local casando bajas y heridos. Es esencial un control eficiente para garantizar la libre circulación de personas y mercancías dentro del territorio nacional. Se debe de proteger el espacio aéreo nacional contra agresiones o violaciones por parte de otros estados o terroristas.

Espacial:

Este ámbito, considerado patrimonio de la humanidad, no es propiedad de ningún estado. Sus diferentes usos civiles, comerciales, militares y de seguridad muchas veces a través de satélites, son de gran interés para la seguridad contra todo tipo de amenazas.

Ciberespacio:

Creado por el ser humano en los años 60, es un ámbito virtual donde se agrupan usuarios a través de distintas redes o sistemas artificiales (líneas de comunicación, páginas web, foros, servicios de Internet). Es un entorno singular sin fronteras definidas, anónimas y asimétricas que se puede utilizar de forma clandestina y sin necesidad de desplazamiento. Incluye mucho más que Internet ya que se incluyen los teléfonos inteligentes, la televisión terrestre y las comunicaciones por satélite. Este es uno de los ámbitos en los cuales más incidencias y amenazas se están recibiendo en las últimas décadas. La gran mayoría de las infraestructuras críticas están conectadas por Internet mediante los sistemas informáticos que manejan multitud de procesos dentro de estas, los cuales pueden ser hakeados para causar serios problemas como cortes de luz y agua, fallos en la red eléctrica, suministro de gas...

2.3.2. Las amenazas para la seguridad nacional de España.

La Seguridad Nacional de España puede verse en riesgo por diversos factores, incluyendo su naturaleza geopolítica, tecnológica, económica o social, entre otras. Las amenazas que pueden poner en riesgo los intereses vitales y estratégicos de España se han incrementadas en los últimos años.

Terrorismo

El terrorismo es una amenaza que merece una atención especial debido a su impacto directo en la vida y la seguridad de los ciudadanos y su capacidad para poner en riesgo infraestructuras críticas que por su caída podrían causar el caos entre la población. La prevención y eliminación del terrorismo, ya sea de origen nacional o transnacional, es un objetivo prioritario para España y Europa.

España tiene una experiencia prolongada en la lucha contra el terrorismo debido a que durante más de 40 años tuvo que luchar contra la lacra del terrorismo de ETA dentro del territorio nacional. Euskadi Ta Askatasuna o ETA fue una organización terrorista nacionalista vasca que se proclamaba independentista, abertzale, socialista y revolucionaria. Durante sus sesenta años de historia esta organización terrorista tuvo por objetivo la constitución de un Estado socialista en Euskal Herria y su independencia de España y Francia utilizaron el asesinato, el secuestro y la extorsión económica para lograr ese fin. En la (figura 6) se observa las víctimas mortales causadas por ETA durante toda su historia.




Figura 6. Víctimas mortales de ETA

Las organizaciones terroristas internacionales, fundamentalmente las yihadistas como Daesh (ISIS), representan una amenaza global. Estas organizaciones utilizan medios de comunicación y redes sociales para el reclutamiento y adoctrinamiento por la red, y realizan atentados en lugares concurridos, incluyendo en la mayoría de los casos infraestructuras críticas de importancia vital. La línea de tendencia de estas organizaciones es llevar a cabo atentados en lugares donde se concentra la población como los medios de transporte, estaciones de trenes, autobuses, aeropuertos... Su modus operandi incluye tanto células organizadas como “lobos solitarios” y su fin es causar el mayor número de víctimas posible, además de generar un fuerte impacto propagandístico. (Estrategia Española de Seguridad, 2013). En la (figura 7) que encontramos más abajo se observan todas las operaciones y detenidos que se llevaron a cabo contra esta organización criminal en tres años en el caso de España.




Figura 7. Operaciones contra Estado Islámico en España

España está comprometida en la lucha contra el terrorismo y su respuesta se basa en un modelo integral coordinando la acción con todos sus aliados en todas las iniciativas internacionales especialmente con la Unión Europea.

La percepción de España como blanco del terrorismo internacional puede verse incrementada por circunstancias como: (Estrategia española de seguridad pag49)

El aumento de su implicación en misiones internacionales, como fue el caso de la guerra de Irak con el presidente Aznar que luego provocó el mayor atentado de la historia en España.

La insistencia de grupos fundamentalistas islámicos en presentar a España como parte del imaginario del Islam con fines de reclutamiento, reivindicando un Al Ándalus musulmán desaparecido hace más de cinco siglos.

La proximidad al Magreb, sometido a considerables y contradictorias fuerzas demográficas, políticas, económicas y de extremismo violento.

La existencia de Estados fallidos, muy preocupantes en el caso del área subsahariana por su relativa proximidad geográfica a las costas españolas, que facilita el desarrollo y las actividades de los grupos terroristas.

El posible efecto contagio de ideologías radicales en grupos de población originarios de zonas conflictivas asentadas en nuestro país, sobretodos residentes de segunda generación.

Crimen organizado

El crimen organizado es otra de las amenazas más graves para la seguridad de cualquier Estado. Tiene una gran capacidad desestabilizadora de los sistemas políticos y económicos de la sociedad española, y su objetivo principal es el lucro, debilitando las instituciones y minando de la gobernanza de las distintas naciones. España, debido a su posición geoestratégica, es un punto de acceso a la Unión Europea para redes criminales de África y América. Como se observa en la (figura 8) en España nos encontramos con una gran variedad de crimen organizado contra el cual se debe de luchar para conseguir un país más seguro.

La trata de personas, blanqueo de capital y Paraísos fiscales: Estos métodos permiten a las organizaciones criminales mover su dinero con libertad, utilizando empresas pantalla.

Vinculación con el terrorismo y la tecnología: La relación entre el crimen organizado y el terrorismo ha crecido, aumentando sus efectos negativos.

Posición geoestratégica de España: Como punto de acceso a la UE, España está expuesta a redes criminales de África y América.



Fuente: Ministerio del Interior de España Figura 8. Crimen organizado en España

La percepción pública del crimen organizado está muy subestimada. Funciona con opacidad y la mayoría de los casos se esconde tras actividades legales, lo que le exime en muchos casos de atraer el debate público como en el caso del terrorismo. Puede llegar a controlar infraestructuras estratégicas y, que no deberían de estar en manos de criminales o empresas privadas estratégicas que son adquiridas por ellos. La ONU estima que el volumen total de negocio del crimen organizado supone alrededor del 10% del PIB mundial (UNODC, 2018). Esta cifra ilustra no sólo el montante de sus actividades y de sus beneficios, sino sobre todo su capacidad de acceso a medios e instrumentos de todo tipo para sustraerse a la acción del Estado, y en particular de la inteligencia y de la policía.

Blanqueo de Capitales:

El blanqueo de capitales por el crimen organizado puede representar entre el 2% y el 5% del PIB mundial según el Fondo Monetario Internacional (FMI). Un estudio de la UE cifra las ventas de droga ilegal en al menos 100.000 millones de euros al año. (FMI, 2019).

Espionaje:

El espionaje ha sido históricamente una de las principales amenazas, ya que la obtención de información de los estados puede otorgar ventajas significativas en futuros enfrentamientos. En la actualidad, el espionaje se ha adaptado a las nuevas tecnologías, beneficiándose del ciberespacio para obtener grandes cantidades de información que son robadas a empresas estratégicas como lo son las infraestructuras críticas de producción eléctrica para luego utilizar esos datos en su beneficio o venderlos para obtener ganancias porque como ya se sabe los datos son el nuevo petróleo del siglo XXI. Casos como el de Edward Snowden han puesto de manifiesto las capacidades y riesgos del espionaje moderno.

La vulnerabilidad del ciberespacio está íntimamente ligada con el espionaje y ha adquirido una dimensión global que va mucho más allá de la tecnología. Para ciudadanos y gobiernos, el ciberespacio y las redes de comunicación y de información son una fuente de posibilidades ilimitadas. Soportan la prestación de servicios ampliamente utilizados, como los buscadores de información, el correo electrónico, así como la gestión de muchas infraestructuras críticas y multitud de servicios privados y la mayoría de los servicios de las Administraciones Públicas.

Ciberseguridad:

La ciberseguridad está estrechamente relacionada con el espionaje, para nuestras sociedades modernas hipertecnológicas, los sistemas económicos actuales basan dichas tecnologías para el normal funcionamiento de todas las infraestructuras críticas de los Estados desarrollados que son las herramientas con las cuales se sostiene este nuevo sistema económico. Dada la importancia vital de los sistemas informáticos en la economía, la estabilidad y prosperidad económica de cualquier país va a depender de las medidas de seguridad implementadas en nuestro ciberespacio y dentro de nuestras infraestructuras críticas para que no haya robos masivos de información relevante para muchos estados y organizaciones. Los ciberataques pueden poner en jaque infraestructuras críticas indispensables para el funcionamiento normal de la sociedad moderna, como se vio en Estonia 2007, Georgia en 2008 o Irán 2010. Estos ataques demostraron el potencial de los ciberataques para causar graves problemas y pérdidas económicas significativas.

España está expuesta como la mayoría de países desarrollados que utilizan asiduamente las nuevas tecnologías de la información y las comunicaciones en multitud de sistemas y redes a ciberataques. La obtención de todo tipo de datos en la red, a menudo para ser vendidos a terceros, es cada vez más preocupante. Además de las pérdidas económicas se socaba la confianza de los consumidores en los sistemas electrónicos de pago que podrían tener profundos efectos desestabilizadores de la economía nacional. (ENISA, 2018).

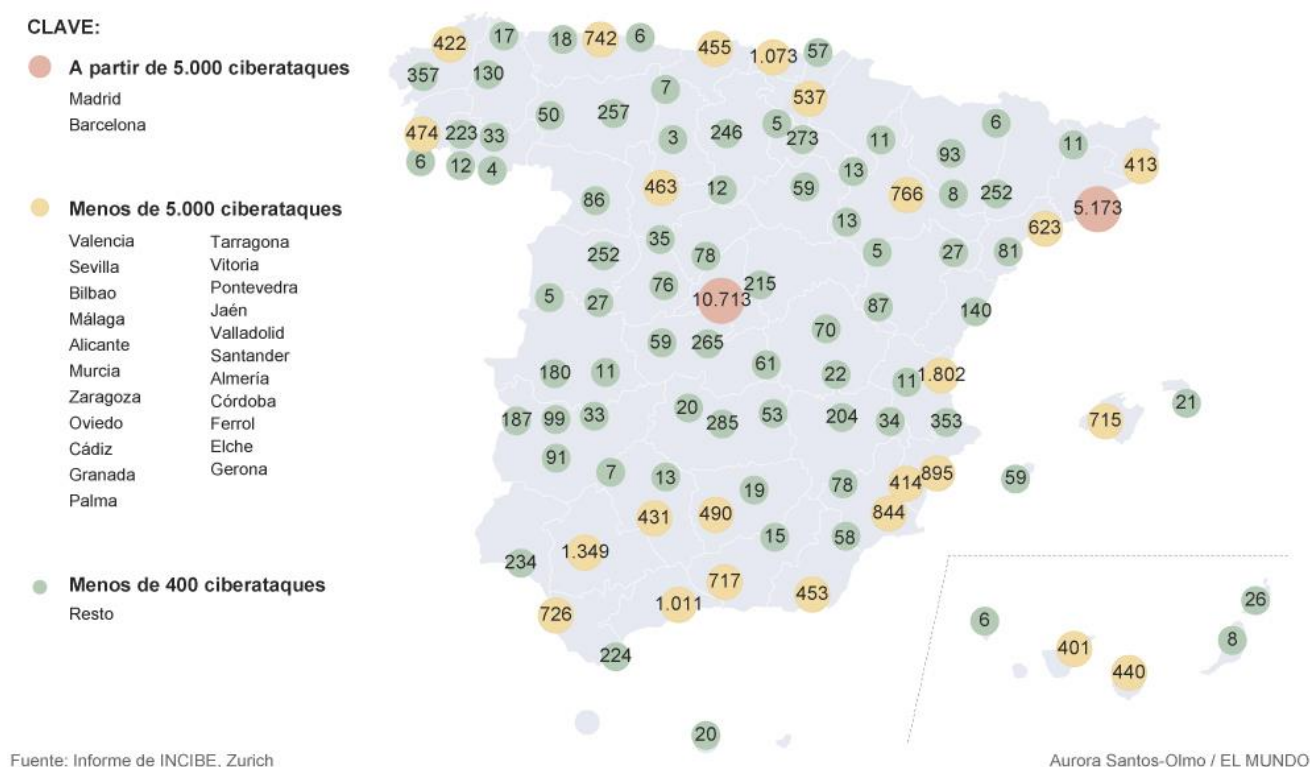
La ausencia de una legislación fuerte y vigente en este aspecto puede incrementar las posibilidades de sufrir ataques que se materialicen en pérdida de información valiosa por parte de instituciones y empresas privadas. ¿Por qué creéis que Internet fue creado para ser útil y sencillo de utilizar?

La incesante interconexión entre todas las redes a nivel mundial, incluyendo infraestructuras, suministros y servicios críticos, incrementan los niveles de riesgo sobre ellos. La dificultad y el anonimato en el rastreo de los ciberataque son factores que entorpecen su neutralización.

España es un nodo importante en una gran variedad de redes por lo que garantizar la seguridad de estas es indispensable para nuestra nación y para los países europeos con los que estamos totalmente interconectados como podréis leer más adelante. Por lo cual es necesario seguir impulsando medidas

para tomar la correcta conciencia y la formación necesaria sobre la multitud de riesgos a los que estamos sometidos. Esto se consigue con las políticas necesarias y la creación de procedimientos y protocolos de seguridad en los sistemas de información de ciudadanos, empresas e instituciones, y reduciendo la dependencia de tecnologías de seguridad de otros países.

Actualmente, es muy común el uso del anonimato para conseguir diferentes propósitos como por ejemplo, la expansión de determinados intereses geopolíticos por parte de Estados, organizaciones terroristas y actores individuales. La ventaja del anonimato que ofrece el ciberespacio es que puedes conseguir cualquier fin a un mínimo coste y asumiendo un riesgo mucho menor. Como se puede apreciar en la (figura 9) los ciberataque en la red española se centran en grandes ciudades donde se acumulan las principales infraestructuras críticas debido a la acumulación de la población en zonas urbanas.



Fuente: Informe INCIBE Figura 9: Ciberataques contra IC del Estado Español

Espacio Marítimo:

El espacio marítimo es de gran relevancia para España, siendo una potencia marítima con un valor estratégico significativo. Las amenazas a la seguridad marítima se concentran en dos grupos principales: actos intencionados y amenazas accidentales.

Las amenazas derivadas de actos intencionados incluyen:

Piratería: Incidentes de piratería representan un riesgo significativo para la navegación y el comercio marítimo. (International Maritime Bureau, 2020).

Terrorismo: Las infraestructuras portuarias y los buques pueden ser objetivos de ataques terroristas. (IMO, 2020).

Tráfico Ilícito: El contrabando de drogas, armas y personas es una preocupación constante y los puertos son las puertas de entrada más normales a los Estados. (Europol, 2020).

Redes de Inmigración Irregular: La inmigración irregular por vía marítima plantea desafíos para la seguridad y la gestión de fronteras.

Explotación Incontrolada de Recursos Marinos: La pesca ilegal y la explotación de recursos naturales sin regulación pueden tener efectos desestabilizadores. (FAO, 2020).

Amenazas Accidentales

Las amenazas accidentales derivadas de las condiciones naturales incluyen:

Accidentes marítimos: Colisiones y naufragios pueden causar grandes pérdidas económicas y ambientales. Un ejemplo destacado es el naufragio del petrolero Prestige frente a las costas del Galicia en 2002, que resultó en una catástrofe ecológica con el vertido de miles de toneladas de fuel al mar, afectando gravemente a la pesca y el turismo en la región. (Loureiro, 2009).

Catástrofes Naturales: Fenómenos como tsunamis, tormentas, erupciones volcánicas caso de la Palma y terremotos caso de Lorca pueden tener un impacto devastador (UNDRR, 2020).

Flujos Migratorios

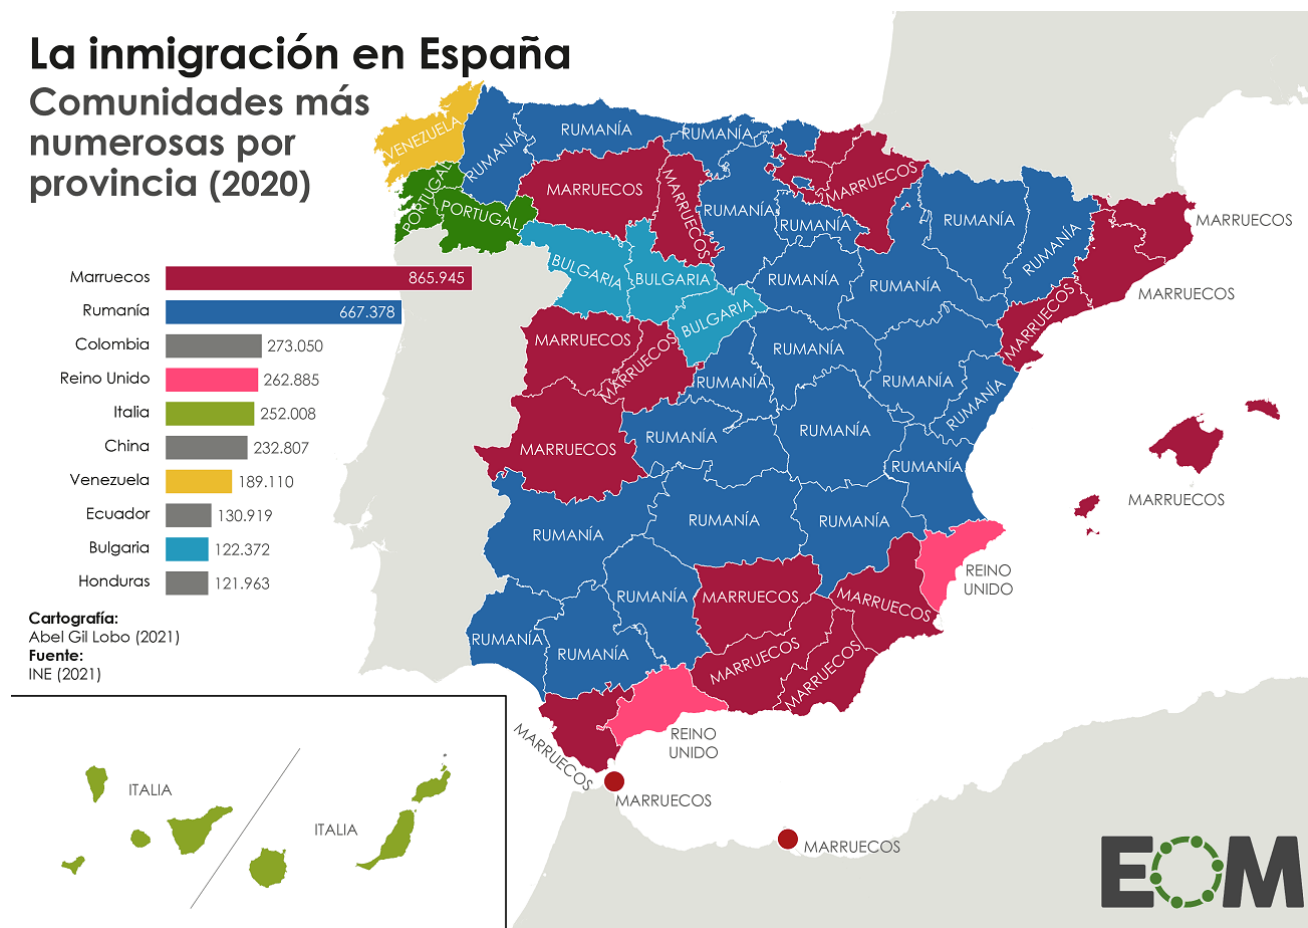
Aunque los flujos migratorios han existido desde la antigüedad, su intensidad y características actuales presentan nuevas amenazas para la seguridad. El crecimiento de la población en África y Asia es previsible que se mantengan he incluso incrementen estos flujos migratorios irregulares si persisten en algunos de ellos la pobreza, la desigualdad, los conflictos étnicos, la sobreexplotación de los recursos naturales, los riesgos medioambientales, la debilidad institucional, los regímenes totalitarios o los conflictos armados.

España como país receptor, enfrenta varias amenazas ya que ha pasado de ser un país de emigración a ser un país receptor de inmigrantes y con una de las poblaciones más diversas de Europa. Se va a incrementar con total seguridad la inmigración irregular desde el continente africano, dada nuestra proximidad geográfica y las nefastas condiciones económicas, sociales y políticas del continente africano. Con sus amenazas como:

Conflictividad social: La inmigración irregular puede ser aprovechada por partidos o grupos racistas o xenófobos para crear inestabilidad en la sociedad (Estrategia Española de Seguridad, 2013).

Guetos urbanos: La formación de guetos puede fomentar la inseguridad y la violencia.

En la (figura 10) se visualizan cuáles son las nacionalidades principales en cada una de las provincias españolas.



Fuente: INE 2021 Abel Gil Lobo Figura 10: La inmigración en España 2021

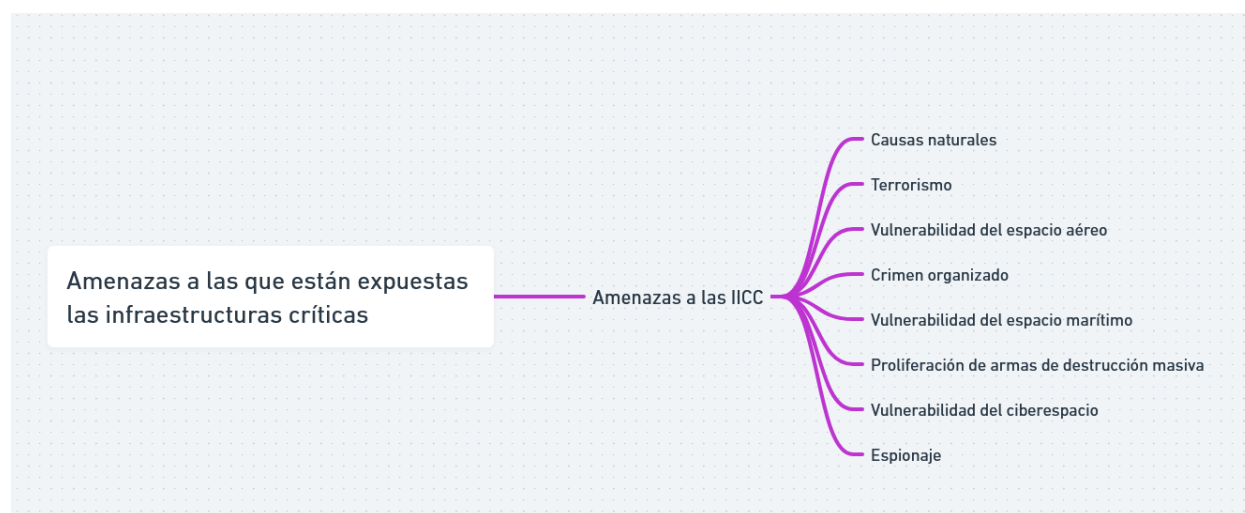
Amenazas ambientales y catástrofes naturales:

Las catástrofes ambientales siguen siendo una preocupación significativa produciendo destrozos con unas consecuencias económicas para las arcas de los Estados, a pesar de los avances tecnológicos para la detección temprana de estos desastres naturales. Ejemplos como el terremoto de Haití, las inundaciones de Pakistán, el huracán Katrina. Las catástrofes también pueden tener lugar por errores de cálculo de los humanos como el desastre de Chernobil o de una combinación de ambas como el tsunami de Japón y consiguiente accidente nuclear en la central nuclear de Fukushima. Las centrales nucleares, por ejemplo, suelen ubicarse en áreas menos propensas a desastres naturales como terremotos y tsunamis. La elección de la ubicación se basa en un análisis geográfica detallado que considera factores como la estabilidad sísmica, la proximidad a cuerpos de agua para el enfriamiento

y la distancia a centros urbanos densamente poblados para minimizar el riesgo a la población en caso de un accidente. Perrow, C. (2011).

Los riesgos ambientales por fenómenos meteorológicos adversos ponen en amenaza la vida de los ciudadanos. Sequías, inundaciones, tormentas, tempestades de viento, u olas de calor o de fría han existido siempre pero ahora pueden ser más intensas por el cambio climático. La implantación de sistemas de alerta y de protección con un enfoque más proactivo basado en la predicción y prevención puede permitirnos ahórranos vidas de ciudadanos y cifras estratosféricas de millones de euros. En la (figura 11) se presenta un organigrama de las amenazas a las que están expuestas todas las infraestructuras críticas.

Las amenazas de origen natural en el caso español son bien conocidas desde hace décadas. Las más comunes y casi endémicas son las inundaciones e incendios forestales. Seísmos y erupciones volcánicas pueden también causar pérdidas humanas y materiales en el espacio español tenemos los ejemplos del terremoto de Lorca y de la erupción volcánica de la Palma recientemente acaecidos.



Fuente: Creación Propia

Figura 11. Organigrama amenazas infraestructuras críticas

3. Antecedentes históricos sobre el marco legal en protección de Infraestructuras Críticas.



Figura 12. Organigrama sobre marco legal.

Se observa en la (figura 12) el organigrama sobre los antecedentes históricos del marco legal para la protección de las infraestructuras críticas en Europa. El impulso inicial se produjo tras los atentados

del 11 de Marzo de 2004 en Madrid, que destacaron la vulnerabilidad de las infraestructuras críticas y la necesidad de su protección integral. La ruta trazada por la Unión Europea, inspirada por estos eventos marco el inicio de un programa que aborda la protección de las infraestructuras críticas desde múltiples perspectivas tanto a nivel nacional como europeo.

Antes de establecer un marco legal y legislativo europeo, se aprobaron las llamadas Comunicaciones Comunitarias de Lucha contra el terrorismo, específicamente las de “Prevención, preparación y respuesta de los ataques terroristas” y “Preparación y Gestión de las Consecuencias del Terrorismo”.

La comunicación en Prevención, Preparación y Respuesta a los Ataques Terroristas proponía intensificar la lucha contra el terrorismo mediante una serie de medidas preventivas. Propone intensificar y mejorar la lucha contra el terrorismo, entre sus propuestas destacaba la implicación de la sociedad civil, parlamentos nacionales, agentes económicos y organizaciones para instaurar herramientas eficaces contra el terrorismo. Los ámbitos de acción incluían:

- Protección de los derechos fundamentales y lucha contra la radicalización de la sociedad.
- Asociación y cooperación de los sectores privado y público.
- Apoyo a las víctimas del terrorismo.

Se promovió un enfoque integrado que incluía la cooperación policial y judicial, así como la cooperación externa para colaborar con otros países en la lucha terrorista. Además se destacó la importancia de la investigación científica y técnica en materia de seguridad, y para finalizar destaca la participación del sector privado para instaurar soluciones para la lucha contra el terrorismo y mejorar la seguridad de bienes y servicios debido a que cada vez más las infraestructuras críticas está en manos privadas.

La comunicación Preparación y Gestión de las Consecuencias del Terrorismo estaba orientada a prever y gestionar las consecuencias de un supuesto ataque terrorista, centrado en la protección civil y la seguridad sanitaria. Entre sus acciones, se incluían mecanismos y formaciones destinados a proteger y ayudar a la población civil en caso de ataques, en particular, bioterroristas y la creación de dispositivos de alerta rápida.

Se fomentó la cooperación a nivel europeo mediante mecanismos como el MIC (Mecanismo de Protección Civil de la Unión Europea). Su función es recibir solicitudes de ayuda de los países afectados de catástrofes y trasmitirlas a los demás países. El MIC interviene en catástrofes como incendios, terremotos, mareas negras, accidentes industriales o atentados terroristas.

Para que estos mecanismos comunitarios de protección civil sean eficaces los Estados miembros deben participar plenamente, esto quiere decir:

- Mejorar la comunicación y la coordinación.
- Garantizar la interoperabilidad de los equipos técnicos, entre el ámbito civil y militar.
- Encontrar los medios para financiar el coste de transporte de los equipos y el personal en caso de catástrofe.

La protección sanitaria es otro de los pilares de esta Comunicación sobre la Lucha contra el terrorismo: preparación y gestión de las consecuencias. Debido a que los incidentes o atentados terroristas con explosivos, agentes químicos o biológicos tendrían consecuencias desastrosas. Los Estados y la comisión adoptaron un programa de cooperación que trata sobre:

- Evaluación de riesgos.
- Detección y exclusión de agentes biológicos, químicos o radioactivos en ambientes humanos animales o plantas.
- Comunicación en materia de riesgos entre las autoridades sanitarias, los profesionales de la salud y la opinión pública.
- Gestión de riesgos.

El siguiente instrumento europeo fue la comunicación 702 la cual se encargara de dar los primeros pasos en la elaboración de una estrategia global de protección de infraestructuras críticas mediante la adopción de medidas homogeneizadoras y una definición común.

La definición de las infraestructuras críticas son aquellas instalaciones, redes, servicios y equipos físicos y de tecnologías de la información cuya interrupción o destrucción tendría un impacto mayor en la salud, la seguridad o el bienestar económico de los ciudadanos o en el eficaz funcionamiento de los gobiernos de los Estados miembros. Las infraestructuras críticas están presentes en numerosos sectores de la economía: actividades bancarias y financieras, transportes y distribución, energía, servicios, salud, abastecimiento de alimentos, administraciones públicas clave. Monica Miranzo y Carlos del Rio. La protección de Infraestructuras Críticas UNISCI

El Programa Europeo para la Protección de Infraestructuras Críticas (PEPIC) fue un paso significativo en la estrategia global de la UE para proteger infraestructuras críticas. Este programa incluyó la creación de un marco legislativo y la insistencia en la preparación de análisis de vulnerabilidades y evaluación de riesgos, fomentando la colaboración entre empresas y administraciones públicas.

La comunicación 702, adopta el 20 de octubre de 2004, propuso la creación de la Red de Información sobre alertas en Infraestructuras críticas (CIWIN), con el objetivo de compartir información sobre amenazas comunes y estrategias de gestión de riesgos.

3.1. Directiva 2008/114/CE

Para dar por completada la estrategia global de protección de infraestructuras críticas, la Unión Europea aprobará el 8 de Diciembre de 2008 la Directiva 2008/114/CE sobre la “Identificación y designación de infraestructuras críticas europeas y la evaluación de las necesidades de mejorar su protección”. La presente Directiva se concentra en los sectores de la energía y de los transportes, con revisión prevista para incluir otros sectores como las TIC.

Existe una serie de infraestructuras críticas europeas cuya perturbación o destrucción tendría repercusiones transfronterizas importantes derivadas de la interdependencia que poseen entre ellas. A estas infraestructuras críticas de suma importancia para más de dos países de la Unión Europea se les llama (ICEs de ahora en adelante) deben identificarse y designarse mediante un planteamiento mínimo común. Los planes bilaterales de cooperación entre Estados miembros en materia de ICEs constituyen un medio eficaz para ello. En la (figura 13) se presenta el organigrama de los principales objetivos de la Directiva 2008/114/CE para la protección de las infraestructuras críticas de todos los países de la UE.

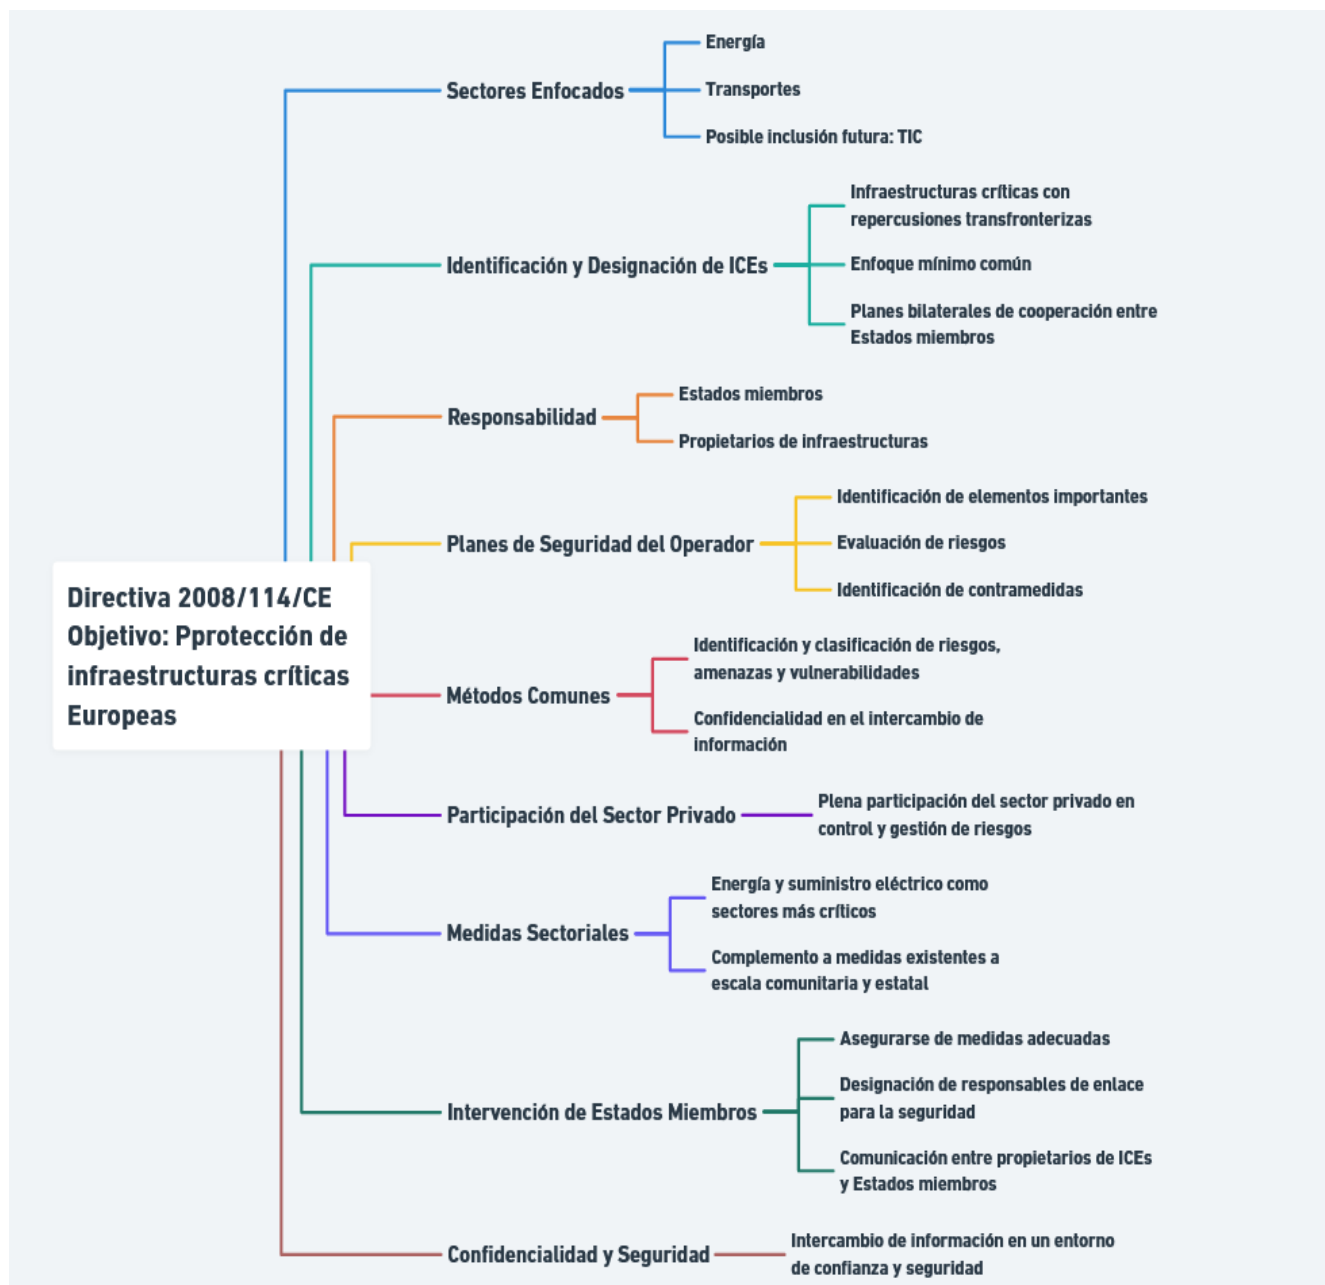


Figura 13. Organigrama de los principales objetivo de la Directiva 2008/114/CE.

Esta directiva establece que la responsabilidad principal de proteger las ICEs corresponde a los estados miembros y los propietarios de dichas infraestructuras. Además, se subrayó la importancia de los planes de seguridad del operador, que deben incluir la identificación de elementos importantes, una evaluación de riesgos y la identificación de contramedidas.

Para facilitar la protección de las ICEs, la directiva propuso métodos para homogeneizar la identificación y clasificación de riesgos, amenazas y vulnerabilidades. Además, fomento la confidencialidad en el intercambio de información entre empresas y organizaciones para garantizar un entorno de confianza.

Dado que varios sectores cuentan con especial experiencia además de necesidades particulares en dichas materias, deben de desarrollarse y aplicarse planteamientos comunitarios de protección de ICEs teniendo en cuenta las características específicas de los diferentes sectores y las medidas existentes a escala comunitaria, nacional o regional. Sabida la experiencia del sector privado en control y gestión de riesgos el planteamiento comunitario debe fomentar la plena participación de dicho sector. El sector energético y en particular los métodos de generación y transporte de la electricidad en relación al suministro eléctrico son los sectores más críticos para el buen funcionamiento del sistema creado alrededor de ellos.

Cada Estado miembro intervendrá oportunamente para asegurarse de que se ponen en marcha medidas adecuadas. Deben considerarse las medidas, principios y directrices así como los planes de cooperación bilaterales y multilaterales similares al plan de seguridad del operador para que la seguridad cumplan con los requisitos que impone la presente Directiva. Se deberán de nombrar responsables de enlace para la seguridad en todas las ICEs designadas con el fin de facilitar la cooperación y la comunicación con las autoridades responsables de dichas infraestructuras. Para poder determinar con eficacia los riesgos, amenazas y vulnerabilidades de los diferentes sectores debe existir una comunicación entre propietarios de las ICEs y los Estados miembros.

Cada Estado miembro debe de reunir la información necesaria sobre todas sus ICEs que se encuentran en su territorio para que la Comisión reciba dicha información y pueda servir de base para elaborar propuestas más específicas de protección. Para facilitar la protección de las ICEs podrán desarrollarse métodos comunes de identificación y clasificación de los riesgos, amenazas y vulnerabilidades sobre los elementos infraestructurales. Para desarrollar dichas actividades de protección se requiere cierto grado de confidencialidad de información en el marco de la presente Directiva. El intercambio de información sobre ICEs debe de producirse en un entorno de confianza y seguridad entre empresas y organizaciones para que sepan que sus datos serán protegidos.

3.2 Legislación Española: Ley 8/2011 del 28 de abril.

En la era contemporánea en la que andamos sumergidos, la globalización y la creciente interconexión de los sistemas económicos, energéticos, de alimentación y de seguridad han alcanzado niveles sin precedentes. La seguridad de las naciones se ha vuelto más compleja y depende cada vez más de la protección de sus infraestructuras más críticas (Miranzo & del Río, 2014). España, alineada con las directrices de la Unión Europea, ha respondido a estos desafíos con la Ley 8/2011, del 28 de abril, de Protección de Infraestructuras Críticas.

La Ley 8/2011 se establece en un marco normativo integral para la identificación, protección y respuesta frente a las amenazas a las infraestructuras vitales para el funcionamiento del Estado español.

La ley fomenta la colaboración entre los sectores público y privado, aportando directrices claras para la identificación y designación de infraestructuras críticas (Estrategia de Seguridad Nacional, 2013). Esta ley no solo define las obligaciones y responsabilidades de todas las entidades integradas, sino también sienta las bases para la implementación de medidas de seguridad coordinadas.

Se establecen una serie de definiciones dentro de esta ley para proporcionar un marco claro y unificado que permita la identificación, clasificación y protección de infraestructuras críticas. Proporcionando definiciones claras garantizan que todos los actores involucrados utilicen los términos de manera consistente. Además permite establecer lo que se considera infraestructura crítica o estratégica para priorizar recursos y esfuerzos de protección, esto asegura un enfoque en los activos más vitales para la sociedad. Estas definiciones provocan una coordinación que antes no existía entre los distintos niveles de gobierno, sectores económicos y fuerzas de seguridad. Para finalizar tener unos criterios concisos permite realizar análisis de riesgos más precisos y efectivos, identificando vulnerabilidades y planificando respuestas adecuadas para las posibles amenazas, para garantizar la seguridad y resiliencia de las infraestructuras críticas.

Término	Definición
Servicio esencial	Servicio necesario para el mantenimiento de funciones sociales básicas (salud, seguridad, bienestar social y económico, y funcionamiento de las administraciones públicas).
Sector estratégico	Áreas diferenciadas en la actividad laboral, económica y productiva que proporcionan un servicio esencial o garantizan la seguridad del país.
Subsector estratégico	Ámbitos en los que se dividen los sectores estratégicos, según lo aprobado por el Centro Nacional de Protección de las Infraestructuras Críticas.
Infraestructuras estratégicas	Instalaciones, redes, sistemas y equipos de TI sobre los que descansa el funcionamiento de los servicios esenciales.

Infraestructuras críticas	Infraestructuras estratégicas cuyo funcionamiento es indispensable y cuya perturbación o destrucción tendría un grave impacto sobre los servicios esenciales.
Infraestructuras críticas europeas (ICE)	Infraestructuras críticas situadas en un Estado miembro de la UE, cuya perturbación afectaría gravemente a al menos dos Estados miembros, según la Directiva 2008/114/CE.
Zona Crítica	Zona geográfica con varias infraestructuras críticas interdependientes, facilitando la protección y coordinación entre operadores y fuerzas de seguridad.
Criterios horizontales de criticidad	Parámetros para determinar la criticidad, gravedad y consecuencias de la perturbación o destrucción de una infraestructura crítica, evaluados en función del número de personas afectadas, impacto económico, impacto medioambiental, e impacto público y social.
Análisis de riesgos	Estudio de hipótesis de amenazas para determinar vulnerabilidades en los sectores estratégicos y las posibles repercusiones de la perturbación o destrucción de las infraestructuras.
Interdependencias	Efectos de una perturbación en el funcionamiento de instalaciones o servicios, distinguiendo repercusiones en el propio sector, otros sectores, y en ámbitos local, autonómico o internacional.
Protección de infraestructuras críticas	Actividades destinadas a asegurar la funcionalidad, continuidad e integridad de las infraestructuras críticas para prevenir, paliar y neutralizar el daño por ataques deliberados.
Información sensible sobre protección de infraestructuras estratégicas	Datos específicos sobre infraestructuras estratégicas cuya divulgación podría utilizarse para planificar ataques.

Operadores críticos	Entidades u organismos responsables del funcionamiento diario de una infraestructura crítica.
Niveles de Seguridad	Grados de intervención de organismos responsables en seguridad, previstos en el Plan Nacional de Protección de Infraestructuras Críticas.

Tabla 1. Definiciones Ley 8/2011

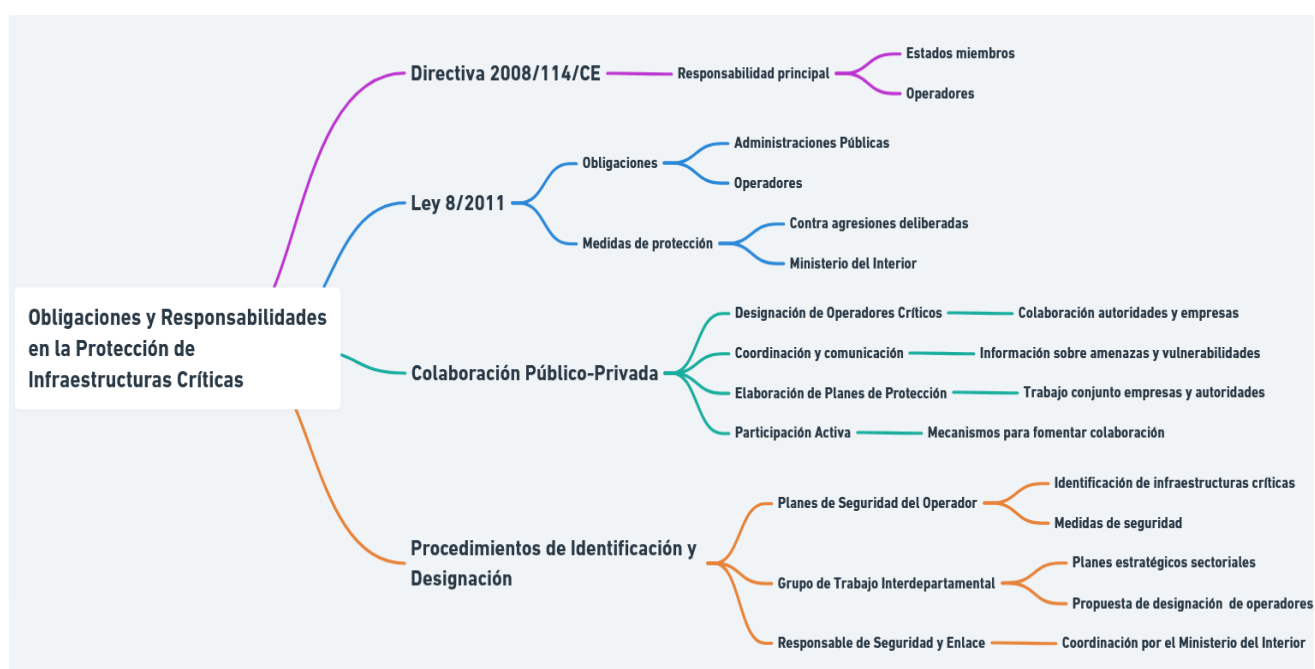


Figura 14. Organigrama obligaciones y responsabilidades en la protección IC

3.3. Directiva 2022/2557

La Directiva 2022/2557 del Parlamento Europeo y del Consejo del 14 de Diciembre de 2022, tiene como objetivo principal aumentar la resiliencia de las entidades críticas de los Estados miembros de la Unión Europea. Esta Directiva deroga la Directiva 2008/144/CE estableciendo un marco más robusto y detallado para garantizar la prestación continua de servicios esenciales que son vitales para la sociedad y la economía (Parlamento Europeo y del Consejo, 2022).

La Directiva establece que los Estados miembros deben adoptar medidas específicas para garantizar la prestación sin obstrucciones de servicios esenciales en el mercado interior. Esto incluye la identificación de entidades críticas y el apoyo a estas en el cumplimiento de sus obligaciones. Las obligaciones principales incluyen:

1. Supervisión de las entidades críticas,
2. Ejecución de medidas de resiliencia.

3. Identificación de las entidades críticas de especial importancia europeas y organización de misiones de asesoramiento para evaluar las medidas adoptadas por dichas entidades.

Además, se establecen procedimientos comunes de cooperación e información para asegurar un alto nivel de resiliencia en las entidades críticas mejorando así el funcionamiento del mercado interior. (Parlamento Europeo y del Consejo, 2022).

3.4. Directiva 2022/2555

La Directivas 2022/2557 se coordina con la Directiva 2022/2555, que aborda la ciberseguridad, garantizando una aplicación integrada de ambas normativas. Esto es esencial debido a la interrelación entre la seguridad física y la ciberseguridad en las entidades críticas (Parlamento Europeo y del Consejo, 2022).

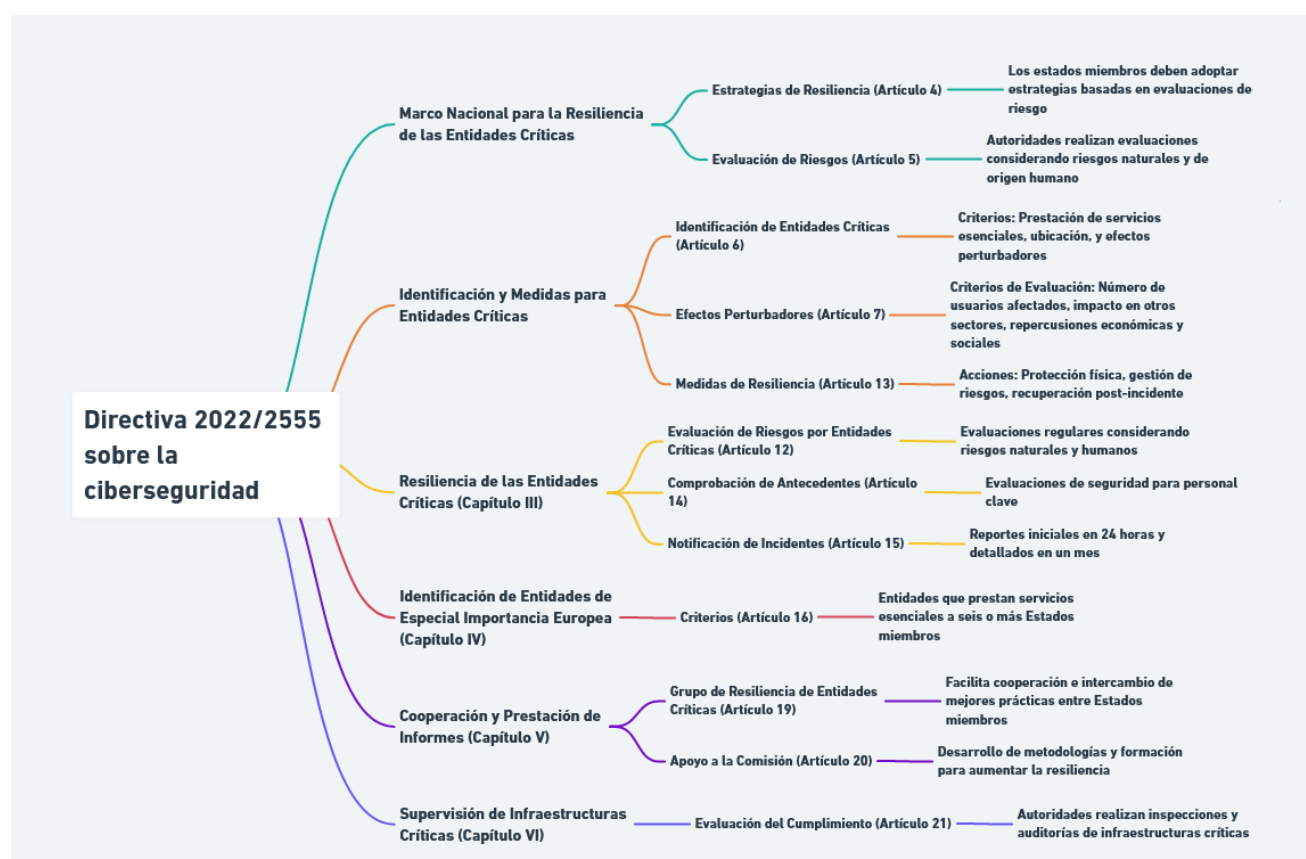


Figura 15. Preceptos de la Directiva 2022/2555.

La presente directiva detalla los marcos nacionales para la resiliencia de las infraestructuras críticas y añade varias definiciones más que no estaban incluidas en las anteriores directivas. Las definiciones van encaminadas sobre todo a:

Estrategias de Resiliencia: Los estados miembros deben adoptar estrategias para aumentar la resiliencia de las entidades críticas, estableciendo objetivos estratégicos y medidas de actuación, basadas en evaluaciones de riesgo y documentos nacionales y sectoriales existentes.

Evaluación de Riesgos: Las autoridades competentes realizarán evaluaciones de riesgos para identificar entidades críticas y ayudarles a adoptar medidas adecuadas. Estas evaluaciones considerarán riesgos naturales y de origen humano, incluyendo los intersectoriales y transfronterizos (Parlamento Europeo y del Consejo, 2022).

Identificación de las Entidades Críticas: Los Estados miembros identificarán las entidades críticas considerando los resultados de las evaluaciones de riesgo y aplicando criterios específicos, como la prestación de servicios esenciales y la ubicación de infraestructuras críticas.

Se aplicarán todos los criterios siguientes:

- a) La entidad presta uno o varios servicios esenciales.
- b) La entidad opera en el territorio de dicho Estado miembro y su infraestructura crítica está situado en él
- c) Un incidente tendría efectos perturbadores significativos.

Efectos perturbadores: Se evaluará el carácter significativo de un efecto perturbador basado en los criterios:

- a) El número de usuarios que dependen de los servicios esenciales prestado por la entidad que se trate.
- b) El grado en que otros sectores y subsectores indicados en el anexo dependen del servicio esencial en cuestión.
- c) Las repercusiones que los incidentes podrían tener, en términos de grado y duración, en las actividades económicas y sociales, el medio ambiente, la seguridad y la protección pública o la salud de la población.
- d) La cuota de mercado de la entidad en el mercado del servicio o servicios esenciales de que se trata.
- e) La zona geográfica que podría verse afectada por un incidente, incluido cualquier repercusión transfronteriza, teniendo en cuenta la vulnerabilidad asociada al aislamiento de ciertos tipos de zonas geográficas, como las regiones insulares, las regiones remotas o las zonas montañosas.
- f) La importancia de las entidades para mantener un nivel suficiente de servicio esencial, teniendo en cuenta la disponibilidad de medios alternativos para la prestación de dicho servicio esencial.

Esta nueva directiva vuelve a promover la cooperación entre los estados miembros en relación con las entidades críticas, garantizando la aplicación coherente de la directiva. Las consultas entre estados miembros serán en relación con las entidades críticas que, utilicen infraestructuras críticas que estén físicamente conectadas entre dos o más Estados miembro. O formen parte de estructuras corporativas que estén conectadas o vinculadas a entidades críticas de otros Estados.

Otros de los artículos de mayor relevancia en esta directiva son sobre la:

Evaluación de riesgos por parte de las entidades críticas: Las entidades críticas deben realizar evaluaciones de riesgos regularmente, considerando riesgos naturales y de origen humano que puedan dar lugar a incidentes, incluidos los intersectoriales y transfronterizos.

Medidas de resiliencia: Las entidades críticas adoptarán medidas técnicas, organizativas y de seguridad adecuadas y proporcionadas para garantizar su resiliencia. Esto incluye:

- a) Evitar que se produzcan incidentes considerando medidas para la reducción del riesgo de catástrofes y de adaptación al cambio climático.
- b) Garantizar una protección física adecuada de sus instalaciones y de las infraestructuras críticas considerando la implantación de vallas, barreras, las herramientas y rutinas de vigilancia perimetral, los equipos de detección y los controles de acceso.
- c) Resistir a las consecuencias de los incidentes y mitigarlos, considerando con la debida atención la aplicación de procedimientos y protocolos de gestión de riesgos y crisis y rutinas de alerta.
- d) Recuperarse del incidente lo antes posible a fin de retomar la prestación del servicio esencial.
- e) Garantizar una protección adecuada de la protección de los empleados.
- f) Concienciar al personal pertinente acerca de las medidas mencionadas además de crear cursos de formación y ejercicios y la elaboración de materiales informativos.

Los pasos para identificar entidades críticas de especial importancia Europea:

- a) Criterios para entidades críticas de especial importancia europea: Una entidad se considera crítica de especial importancia europea si presta servicios esenciales a seis o más Estados miembros.
- b) Misiones de Asesoramiento (Artículo 18): La comisión organizará misiones de asesoramiento para evaluar y mejorar las medidas adoptadas por las entidades críticas de especial importancia europea.

En el artículo 27 queda derogada la directiva 2008/114/CE con efecto a partir del 18 de octubre de 2024. La presente Directiva entrará en vigor a los veinte días de su publicación en el Diario Oficial de la Unión europea.

4. Metodología para la creación de Escenarios de Ataque

En la actualidad, la seguridad de las infraestructuras críticas y su población circundante en España, es un tema de creciente relevancia, impulsado tanto por ataques recientes como se ha podido ver en la (figura 9), como por el reconocimiento de la creciente interdependencia de estas infraestructuras críticas en nuestra sociedad y en el conjunto de la Unión Europea. La globalización y la tecnificación han aumentado la conectividad entre infraestructuras críticas, amplificando los efectos potenciales de cualquier interrupción (Goodchild, 2007). Eventos recientes, como desastres naturales, ataques cibernéticos y crisis sanitarias, han evidenciado la importancia de una infraestructura robusta y resilientes (European Commission, 2022). Estos eventos subrayan la necesidad de entender mejor cómo la degradación o el fallo de una infraestructura crítica puede tener efectos dominó en otras infraestructuras y en la sociedad en general.

En el panorama actual de la investigación mediante herramientas como los SIG y teledetección, el estudio de las infraestructuras críticas se ha convertido en un campo vital en nuestros días. Las tecnologías GIS permiten un análisis detallado de la ubicación, el estado, la interconexión y los posibles efectos adversos que pueden llegar a presentar estas infraestructuras, mientras que la teledetección proporciona datos actualizados y en tiempos real que son cruciales para la monitorización y la respuesta rápida ante emergencias. (Goodchild, 2007). Este estudio se inserta en un contexto donde la capacidad de analizar grandes conjuntos de datos geoespaciales es más accesible que nunca pero hace falta personas cualificadas técnicamente para ello, permitiendo investigaciones profundas sobre cómo las infraestructuras críticas impactan y son impactadas por el entorno humano y natural (Krieger & Demuth, 2014). Además, la integración de técnicas de SIG y teledetección en la evaluación de la seguridad de infraestructuras críticas refleja un enfoque multidisciplinar, que es esencial para abordar la complejidad y la naturaleza interconectada de estos sistemas. (Openshaw, 1983).

Por lo tanto, este estudio no solo responde a una necesidad inmediata de entender y mejorar la resiliencia de las infraestructuras críticas de España, sino también contribuye al campo académico y práctico proporcionando perspectivas y metodologías que pueden ser aplicadas en otros contextos y regiones. Al hacerlo, se alinea con las tendencias globales de la investigación de infraestructuras críticas, marcando un paso hacia adelante en la manera en que utilizamos las tecnología para proteger y mejorar y dar mayor resiliencia a nuestras sociedades (Zerger & Wealands, 2004).

4.1. Herramientas y técnicas para el estudio de los riesgos asociados a las Infraestructuras Críticas.

Python es un lenguaje de programación de alto nivel, interpretado y de propósito general, es conocido por ser uno de los más simples de entender y de mayor legibilidad del código. Fue creado por Guido

van Rossum y lanzado por primera vez en 1991. Es útil en áreas tan diferentes como la informática, ingeniería, ciencias económicas y ciencias sociales como la geografía. El auge en la empleo de esta herramienta se debe a una sintaxis clara y legible que facilita su lectura. Además es compatible con múltiples sistemas operativos, incluyendo Windows, macOS y Linux. Otra de sus cualidades más apreciadas es la amplia gama de bibliotecas y módulos que permiten la realización de tareas complejas, desde el análisis de datos (pandas, Numpy) hasta de aprendizaje automático (scikit-learn) y la visualización (Matplotlib, Seaborn).

Python en sus inicios fue creado para el scripting, que es la automatización de tareas y procesos diversos. Permite automatizar tareas repetitivas cuando se trabaja con grandes conjuntos de datos en una amplia gama de formatos, esto permite un análisis detallado del objeto de estudio. Por ejemplo, la automatización en la clasificaciones de imágenes satelitales o la generación de buffers, overlays, limpieza de datos, transformación de geometrías etc. Estos scripts automatizados pueden ser reutilizados para diferentes conjuntos de datos simplemente cambiando la ruta del archivo. Esto asegura que todas las transformaciones necesarias se realicen de manera consistente y rápida. Los scripts en Python pueden procesar grandes volúmenes de datos a una velocidad mayor que los SIG.

En nuestro caso de estudio se utilizara Python en primer lugar para la limpieza de nuestros datos, en segundo lugar para la creación de buffers de nuestras capas con anterioridad y así no tener que realizar esta tarea que consume mucha memoria en otros procesos subsecuentes. Para finalmente desarrollar la aplicación final que nos surtirá de los resultados de nuestro proyecto que son las combinaciones entre los elementos de las infraestructuras y sus afecciones a la población circundante para saber que regiones de España tienen un mayor riesgo dependiendo de las combinaciones realizadas entre las infraestructuras deseadas.

En la realización de este trabajo final de máster, se ha utilizado Anaconda y dentro de este entorno también llamada entorno de desarrollo (IDE), Jupyter Notebook, como herramienta fundamental para el desarrollo y análisis de los datos geoespaciales. Anaconda es una distribución de Python y R para la ciencia de datos y el aprendizaje automático que simplifica la gestión de paquetes y entornos. Su adopción a este proyecto se debe básicamente a la gestión de entornos virtuales, lo que permite aislar las dependencias del proyecto y evitar conflictos entre distintos paquetes. Esto es esencial para un trabajo académico como este que requiere reproductibilidad y consistencia en los resultados. El siguiente motivo de su elección fue la amplia biblioteca de paquetes que posee para el análisis y visualización de datos. Además de la gestión centralizada de estos paquetes mediante la consola de Conda donde puedes actualizar versiones de paquetes o poner alguna versión más antigua que presente alguna herramienta específica que tu necesites.

Jupyter Notebook es una aplicación web de código abierto con el kernel de Python dentro, que permite crear y compartir documentos que contienen código en vivo, ecuaciones, visualizaciones y texto explicativo. Es una herramienta muy popular en el ámbito de la ciencia de datos y la educación debido a su flexibilidad y capacidad para combinar diferentes tipos de contenido en un solo documento. Los puntos fuertes de Jupyter Notebook son, que al ser interactivo permite ejecutar los scripts por partes mostrando inmediatamente los resultados debajo del código. Por otro lado posee soporte multilenguaje a través del uso de distintos kernels aunque fue concebido originalmente para Python. Además una de las características más apreciadas es la visualización de datos inmediata mediante la creación de gráficos y visualizaciones integradas usando bibliotecas como Matplotlib o plotly lo que es crucial para el análisis de datos. Jupyter Notebook se engloba perfectamente dentro de las herramientas de SIG y Teledetección para el procesamiento y posterior análisis de los datos permitiendo a todo investigador que se precie documentar su flujo de trabajo para la posterior revisión de otros investigadores y probar diferentes enfoques y visualizaciones de datos geoespaciales de manera eficiente.

Este trabajo, se enfocara en encontrar las zonas de mayor riesgo en el Estado español para la población, en función del número de elementos de esa infraestructura y su población acumulada en estas zonas. La metodología adoptada en este estudio es fundamental para garantizar la precisión, la reproducibilidad y la relevancia de los resultados obtenidos, proporcionando así perspectivas valiosas para la planificación, la mitigación de riesgos y la toma de decisiones estratégicas y de seguridad para España.

Este estudio se estructura al principio alrededor de un conjunto de geoanálisis, desarrollados mediante distintos scripts de Python, cada uno diseñado para investigar aspectos específicos de riesgos asociados con diferentes tipos de infraestructuras críticas, como son por ejemplo depósitos de combustibles, estaciones de telecomunicaciones, líneas eléctricas, puertos, estaciones, embalses etc.

Se utilizará un enfoque geoespacial integrando y analizando datos de múltiples fuente, aplicando técnicas avanzadas de GIS pero dentro del ambiente de Jupyter notebooks con el lenguaje de programación de Python. Esta combinación de herramientas nos permite trabajar con datos georreferenciados y desarrollar procesos y automatizar todas las tareas a una mayor velocidad que los antiguos sistemas de información geográfica tradicionales, que requieren procesos manuales mediante interfaces gráficas. (Cutter, Boruff, & Shirley, 2003).

Mediante un enfoque paso a paso, explicare como se preparan los datos para el análisis, como se realizan las intersecciones espaciales y como se integran los resultados individuales para obtener una visión holística del riesgo que podrían causar determinados fallos en estas infraestructuras en el contexto nacional de España y como afectarían posibles escenarios de atentados contra el estado

español. En resumen cuanta gente se podría ver afectada por la caída de estas infraestructuras causando afectados y muertes.

Este enfoque metodológico no solo permite identificar las áreas de mayor riesgo sino también facilita la comprensión de las dinámicas espaciales que definen la interacción entre las infraestructuras críticas y el tejido social y económico del país. Al final de este documento, los resultados de nuestra investigación ofrecerán perspectivas clave para la mejora de las estrategias de planificación urbana y regional, contribuyendo así a la resiliencia y seguridad de la infraestructura críticas de España.

La implementación del script en Python tiene como objetivo identificar aquellas zonas de España que son más críticas y requieren mayor atención en términos de protección debido a la concentración de infraestructuras críticas en zonas densamente pobladas. Este script permitirá: Un análisis geoespacial de las infraestructuras críticas distribuidas en el territorio español. El desarrollo de una herramienta como esta para la protección de infraestructuras críticas es esencial para alcanzar los objetivos planteados.

En la (tabla 2) se pueden visualizar todos los sectores y subsectores que están incluidos en los anexos de la Directiva 2022/2555 de los cuales se seleccionaron algunas infraestructuras críticas dentro de ellos para su estudio como son los sectores energéticos, de transporte, sanidad...

Sectores	Subsectores
1. Energía	a) Electricidad
	b) Sistemas urbanos de calefacción y refrigeración
	c) Crudo
	d) Gas
	e) Hidrógeno
2. Transporte	a) Transporte aéreo
	b) Transporte por ferrocarril
	c) Transporte marítimo y fluvial
	d) Transporte por carretera
	e) Transporte público
3. Banca	
4. Infraestructuras de los mercados financieros	
5. Sanidad	
6. Agua potable	
7. Aguas residuales	
8. Infraestructura digital	
9. Administración pública	
10. Espacio	

11. Producción, transformación y distribución de alimentos	
--	--

Tabla 2. Sectores y Subsectores dentro de la Directiva 2022/2555 vigente en materia de Infraestructuras Críticas.

4.2. Fuentes de información.

Toda la información referente a las infraestructuras críticas de España fue descargada desde el IGN que es una entidad pública encargada de la cartografía, geodesia, y observación del territorio en España. Esta página web ofrece información geográfica oficial y precisa, que es crucial para multitud de aplicaciones y la obtención de resultados válidos. Las infraestructuras críticas seleccionadas para el proyecto fueron:

1. Los depósitos de combustibles: Almacenan combustible esencial para el transporte y la industria. Un incidente aquí podría desencadenar no solo problemas de suministro, sino también riesgos ambientales y de salud pública.


<p>Título de la Capa: Depósitos de combustible.</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
--	--

Tabla 3. Fuentes de información. Capa de depósitos de combustible.

2. Embalses: Cruciales para el suministro de agua, para la agricultura y la generación de energía hidroeléctrica. Su gestión afecta a la disponibilidad de recursos hídricos y la prevención de inundaciones.


<p>Título de la Capa: Embalses</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
--	--

Tabla 4. Fuentes de información. Capa de embalses.

- Estaciones de Telecomunicaciones: Son el núcleo de la comunicación y la información, fundamentales para la coordinación en situaciones de emergencia y la vida cotidiana.


<p>Título de la Capa: Estaciones de telecomunicación.</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
---	--

Tabla 5. Fuentes de información. Capa estaciones de telecomunicación.

- Hospitales: Proporcionan los servicios médicos esenciales. Su funcionamiento es vital durante emergencias para atender a los heridos y la gestión de crisis sanitarias.

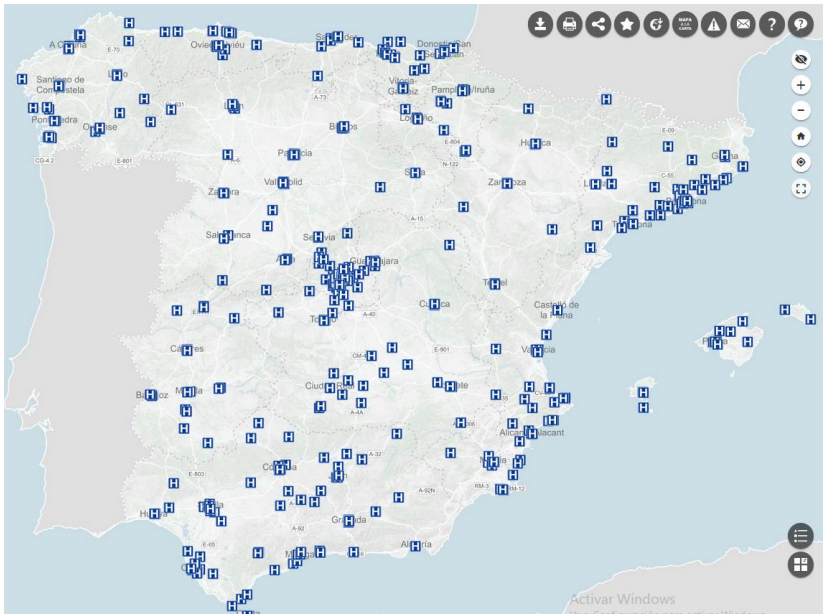
<p>Título de la Capa: Hospitales</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
---	--

Tabla 6. Fuentes de información. Capa de hospitales.

5. Red de autopistas: Esenciales para el transporte y la logística. Un fallo aquí podría aislar regiones, afectando a la economía y la respuesta a emergencias.

<p>Título de la Capa: Red de autopistas</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
--	--

Tabla 7. Fuentes de información. Capa red de autopistas

6. Red hidrográfica (Ríos Principales): Importancia para el suministro de agua, la biodiversidad y como vías de transporte. Su contaminación o alteración tienen efectos extensión y la población.

<p>Título de la Capa: Red hidrográfica principales ríos.</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
--	--

Tabla 8. Fuentes de información. Capa ríos principales.

7. Centrales Eléctricas (Nucleares, Eólicas, solares y térmicas): Claves para la producción de energía. Su operación segura es crucial para evitar desastres ambientales y garantizar el suministro energético.

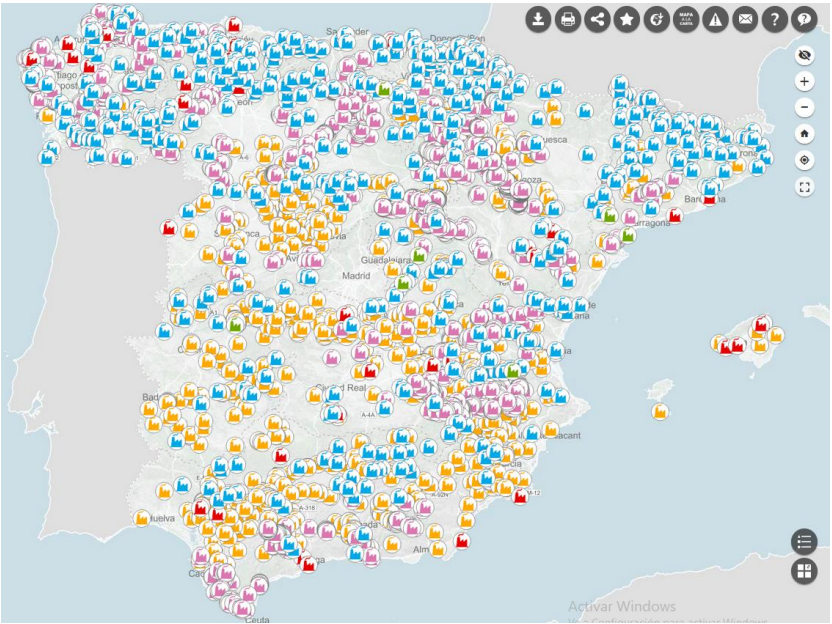
<p>Título de la Capa: Centrales eléctricas</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
--	--

Tabla 9. Fuentes de información. Capa centrales eléctricas.

8. Estaciones de trenes: Puntos neurálgicos para el transporte de pasajeros y mercancías importantes para la movilidad y la economía.

Título de la Capa: Estaciones de trenes.

Autor: Instituto Geográfico Nacional (IGN).

Fecha de Publicación: 2023

Escala: Nacional

Sistema de Referencia: EPSG: 4326

Formato de Archivo: GeoJSON.

Acceso:
<https://signa.ign.es/signa/>

Fecha de Acceso: 7 de Diciembre

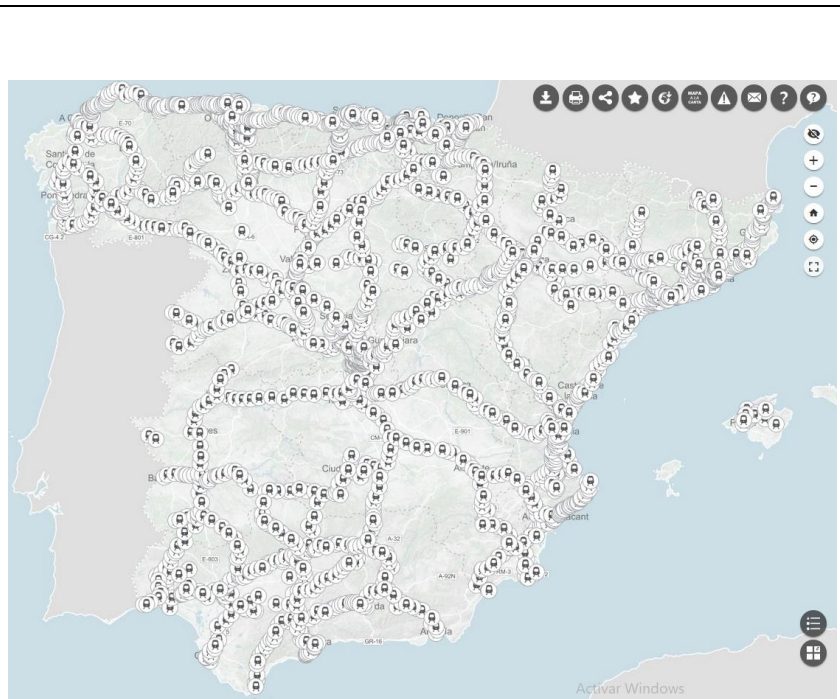


Tabla 10. Fuentes de información. Capa estaciones de tren.

9. Aeropuertos: Esenciales para el transporte aéreo, tienen un papel crucial en la conectividad, el comercio y en situaciones de evacuación.

Título de la Capa: Aeropuertos

Autor: Instituto Geográfico Nacional (IGN).

Fecha de Publicación: 2023

Escala: Nacional

Sistema de Referencia: EPSG: 4326

Formato de Archivo: GeoJSON.

Acceso:
<https://signa.ign.es/signa/>

Fecha de Acceso: 7 de Diciembre

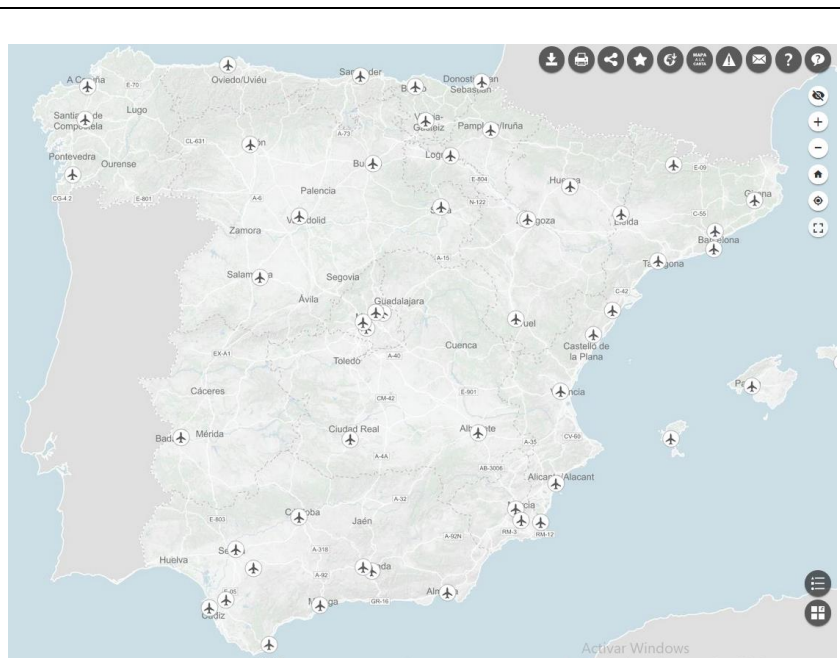



Tabla 11. Fuentes de información. Capa aeropuertos.

10. Puertos: Vitales para el comercio y la recepción de recursos, su operatividad es fundamental para la economía y el abastecimiento.

<p>Título de la Capa: Puertos</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
---	--

Tabla 12. Fuentes de información. Capa puertos.

11. Universidades: Las universidades son claves para la educación y formación de profesionales, la investigación e innovación, y el desarrollo económico. Además, promueven el progreso social, la trasferencia de conocimiento y la colaboración internacional para abordar desafíos globales y fomentan valores culturales y éticos.

<p>Título de la Capa: Universidades</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
---	--

--	--

Tabla 13. Fuentes de información. Capa universidades.

11. Zonas Militares: Claves para la defensa y la seguridad nacional. Proteger activos estratégicos y son esenciales en la respuesta a amenazas y desastres.

<p>Título de la Capa: Zonas militares</p> <p>Autor: Instituto Geográfico Nacional (IGN).</p> <p>Fecha de Publicación: 2023</p> <p>Escala: Nacional</p> <p>Sistema de Referencia: EPSG: 4326</p> <p>Formato de Archivo: GeoJSON.</p> <p>Acceso: https://signa.ign.es/signa/</p> <p>Fecha de Acceso: 7 de Diciembre</p>	
--	---

Tabla 14. Fuentes de información. Capa zonas militares.

4.3. Análisis y caracterización de datos mediante Geoprocesamientos.

En esta sección del proyecto se realizaron una serie de análisis geoespaciales con las distintas capas de infraestructuras críticas de España que se habían descargado con anterioridad. El propósito fue investigar y a la vez a aprender a utilizar todas estas nuevas herramientas para entender la composición de los datos geoespaciales, evaluar que análisis espaciales se podrían hacer con ellas y determinar

posibles eventos adversos para nuestras infraestructuras. Mediante la preparación, carga y verificación de datos geospaciales, así como la aplicación de técnicas avanzadas se estableció una base sólida para ir identificando áreas de riesgo y hacernos una idea de las funcionalidades de estas infraestructuras.

4.3.1. Geoanálisis sobre la red hidrográfica, municipios, autopistas y hospitales.

En primer lugar y para garantizar la reproducibilidad y eficiencia del análisis, se configuró un entorno de desarrollo de Python utilizando herramientas como Anaconda (figura 16), lo que te permite gestionar dependencias y versiones de las librerías de forma aislada y así sacar el máximo provecho a ellas.

```
1 # Crear un entorno virtual en Anaconda
2 Mediante el comando conda create nombre geo_env
   Python=3.8 es la versión de Python que le quieras
   poner a tu ambiente dependerá de lo que quieras
   utilizar deberas instalar una u otra.
3 Mediante el conda activate geo_env se activa el
   ambiente dentro de tu IDE de anaconda
4 Mediante el conda install nombre de todas las librerías
   as que necesite tu ambiente por ejemplo en mi
   ambiente añadi Rasterio, Geopandas matplotlib Folium
   y muchas más para todo el desarrollo de mi
   proyecto final de Máster.
```

Figura 16. Creación entorno virtual.

Seguidamente para el análisis geoespacial con las capas seleccionadas, es la importación de las librerías esenciales para este determinado análisis se puede observar el proceso en la (figura 17).

GeoPandas: Para cargar y manipular datos geospaciales en formato GeoDataFrame.

Matplotlib: Para la generación de gráficas y visualizaciones

Folium: Para la creación de mapas interactivos.

```
1 # Las bibliotecas que se van a utilizar para este
   geoanálisis
2 import geopandas as gpd
3 import matplotlib.pyplot as plt
4 import folium
```

Figura 17. Importación de librerías.

La carga de los datos geospaciales para este análisis proviene de diversas fuentes, cada una con un formato específico que permite detallar distintos aspectos del territorio español. Este proceso se visualiza en la (Figura 18):

Municipios: Archivo SHP que contiene información geográfica y administrativa de todos los municipios de España.

Ríos principales: Archivo GeoJSON que detalla la red hidrográfica de los principales ríos de España.

Red de Autopistas: Archivo GeoJSON que muestra las principales autopistas, crucial para análisis de accesibilidad y evacuación.

Hospitales: Archivo GeoJSON con la ubicación de hospitales, esencial para planificación de servicios de emergencia y salud pública.

```
1 municipios = gpd.read_file(r'C:\Users\mlain\anaconda3\
  envs\ambiente_geopandas_rasterio\Capas_IC\
  Municipios\audes2010-mun\shp\audes2010-mun.shp')
2 rios = gpd.read_file(r'C:\Users\mlain\anaconda3\envs\
  ambiente_geopandas_rasterio\Capas_IC\Red_hidrográ
  fica\rios_principales.geojson')
3 red_autopistas = gpd.read_file(r'C:\Users\mlain\
  anaconda3\envs\ambiente_geopandas_rasterio\Capas_IC
  \Red_carreteras\Autopistas\Autopistas.geojson')
4 hospitales = gpd.read_file(r'C:\Users\mlain\anaconda3\
  envs\ambiente_geopandas_rasterio\Capas_IC\
  Hospitales\hospitales.geojson')
```

Figura 18. La carga de los datos.

Las rutas a los archivos de datos se definieron claramente, apuntando a ubicaciones específicas para asegurar una referencia directa y reducir errores en la carga de datos.

En el subsecuente paso se verificaron los datos con el objetivo de confirmar que los datos se han cargado correctamente y están en formato adecuado para los análisis futuros.

Para este proceso de verificación utiliza el método `.info()` para obtener un resumen de los DataFrames, lo que permite verificar la presencia y el tipo de las columnas, especialmente aquellas clave para el análisis, como las coordenadas geográficas, datos demográficos...

Para la visualización de las primeras entradas se emplea el método `.head()` el cual permite visualizar las primeras filas de cada conjunto de datos, asegurando que la carga de datos sea correcta y que la información relevante este presente. También se puede utilizar el método `.tail()` para ver las últimas filas de nuestro conjunto de datos.

```
1 # Información General
2 print(municipios.info())
3 print(rios.info())
```

Figura 18. Visualizar información con `info()`

```
1 # Información de las columnas de cada capa
2 print(municipios.head())
3 print(rios.head())
```

Figura 19. Visualizar información con función `.head()` `.tail()`

Uno de los pasos más importantes es establecer y verificar un CRS común para todas las capas(Figura 20). Se transforman todas las capas al CRS 'EPSG: 25830' debido a que este sistema de referencia es ampliamente utilizado para estudios detallados en España porque está adaptado para minimizar las distorsiones en escalas nacionales, lo que es crucial para cálculos precisos de distancias y áreas.

```

1 # Transformación del CRS y verificación del mismo
2 municipios.crs = "EPSG:4326"
3 municipios = municipios.to_crs("EPSG:25830")
4 rios = rios.to_crs("EPSG:25830")
5 red_autopistas = red_autopistas.to_crs("EPSG:25830")
6 hospitales = hospitales.to_crs("EPSG:25830")
7 print(municipios.crs)
8 print(rios.crs)
9 print(red_autopistas.crs)
10 print(hospitales.crs)

```

Figura 20. Establecer nuevo CRS con función .to_crs

Esta parte de la metodología de este geonálisis se enfoca en la aplicación práctica de técnicas avanzadas de análisis espaciales para entender y visualizar el impacto de la red hidrográfica en las infraestructuras críticas.

El siguiente paso fue crear una variable que encapsulara el tamaño de los buffers y los guardara en memoria que en este caso fue de un kilómetro alrededor de cada río de nuestra capa (Figura 21). Los buffers son utilizados para simular áreas potenciales de desbordamiento de los ríos, proporcionando una zona de estudio para evaluar el impacto del agua en las áreas circundantes, especialmente en situaciones de lluvias intensas. Los buffers son zonas perimetrales que se extienden a una distancia específica alrededor de los objetos geográficos en este caso los ríos.

```

1 # Crear buffers alrededor de los ríos.
2 # Definir el tamaño del buffer, por ejemplo, 500
  metros
3 buffer_size = 1000 # metros
4 rios_buffered = rios.buffer(buffer_size)

```

Figura 21. Creación buffers con función .buffer

Seguido a la creación de los buffers la función overlay de GeoPandas se utiliza para identificar que municipios intersectan con los buffers de ríos, lo cual indica áreas potenciales de impacto en casos de desbordamiento. Esta operación de intersección permite identificar qué áreas críticas se encuentran dentro de los límites de las zonas de riesgo establecidas por los buffers. El análisis de intersección (figura 22) es fundamental para determinar las áreas que requieren atención prioritaria en términos de planificación de medidas de mitigación y preparación de emergencias.

```

1 if isinstance(rios_buffered, gpd.GeoSeries):
2     rios_buffered = gpd.GeoDataFrame(geometry=
      rios_buffered)
3 # Intersección de municipios con áreas de
  desbordamiento
4 municipios_afectados = gpd.overlay(municipios,
      rios_buffered, how='intersection')

```

Figura 22. Función overlay para intersectar los datos.

El siguiente paso es el impacto de las zonas de desbordamiento sobre infraestructuras críticas, incluyendo hospitales y autopistas, esenciales para la planificación de emergencias y la respuesta rápida. Aplicar la función overlay para determinar que hospitales y tramos de autopistas caen dentro de los buffers.

```

1 # Ahora que todo está en el mismo CRS, podemos
  realizar la operación de overlay
2 autopistas_afectadas = gpd.overlay(red_autopistas,
  rios_buffered, how='intersection')
3 hospitales_afectados = gpd.overlay(hospitales,
  rios_buffered, how='intersection')

```

Figura 23. Función overlay entre buffers y red de autopistas y hospitales.

También se quiso obtener que hospitales se verían afectados y que tramos de autopista por lo tanto mediante este pequeño script obtuve la información.

```

1 # Listar los hospitales afectados
2 print("Hospitales afectados:")
3 print(hospitales_afectados[['etiqueta']])
4
5 # Listar las autopistas afectadas
6 print("\nAutopistas afectadas:")
7 print(autopistas_afectadas[['nombre']])

```

Figura 24. Listar hospitales u tramos de autopista afectados.

Esta vez se quiso una visualización interactiva mediante Folium otra de las muchas librerías de Python en este caso para representar la información en Folium es esencial garantizar que todos los conjuntos de datos estén en el mismo sistema de Referencia de Coordenadas (CRS) que se utiliza en las plataformas de mapeo web, típicamente el EPSG: 4326. Este paso es crucial para la correcta alineación y representación de los datos geográficos en el mapa interactivo.

```

1 # Transformación al CRS que folium necesita para su
  posterior representación.
2 rios_buffered = rios_buffered.to_crs(epsg=4326)
3 municipios_afectados = municipios_afectados.to_crs(
  epsg=4326)
4 autopistas_afectadas = autopistas_afectadas.to_crs(
  epsg=4326)
5 hospitales_afectados = hospitales_afectados.to_crs(
  epsg=4326)

```

Figura 25. Transformación crs para trabajar con Folium.

Para la visualización de la información geográfica en Folium, se debe especificar una localización central y un nivel de acercamiento inicial para la península ibérica. Este mapa sirve como lienzo base sobre el cual se añadirán múltiples capas de datos geoespaciales. Luego se añaden las demás capas necesarias para nuestra visualización como las áreas de desbordamiento y las autopistas y hospitales que fueron afectados por este desbordamiento de los ríos de mayor importancia en España.


```

1 # Creacion del mapa en folium
2 mapa = folium.Map(location=[40.0, -3.5], zoom_start=6)
3
4 # Añadir los ríos al mapa
5 for idx, rio in rios.iterrows():
6     folium.GeoJson(rio['geometry'], name='Ríos').
7         add_to(mapa)
8
9 # Añadir áreas de desbordamiento (buffers) al mapa
10 for idx, area in rios_buffered.iterrows():
11     folium.GeoJson(area['geometry'], name='Áreas de
12         Desbordamiento', style_function=lambda x: {'
13             color': 'blue', 'fillColor': 'blue', '
14             fillOpacity': 0.5}).add_to(mapa)
15
16 # Añadir autopistas afectadas al mapa con tooltip
17 for idx, autopista in autopistas_afectadas.iterrows():
18     tooltip = folium.Tooltip(autopista['nombre']) #
19     Usando 'nombre' para la tooltip
20     folium.GeoJson(autopista['geometry'], name='
21         Autopistas Afectadas', style_function=lambda x:
22         {'color': 'red'}, tooltip=tooltip).add_to(mapa)
23
24 # Añadir hospitales afectados al mapa con tooltip
25 for idx, hospital in hospitales_afectados.iterrows():
26     tooltip = folium.Tooltip(hospital['etiqueta'])
27     folium.GeoJson(hospital['geometry'], name='
28         Hospitales Afectados', style_function=lambda x:
29         {'color': 'green'}, tooltip=tooltip).add_to(
30         mapa)
31
32 folium.LayerControl().add_to(mapa)
33 mapa

```

Figura 26. Creación del mapa en Folium.

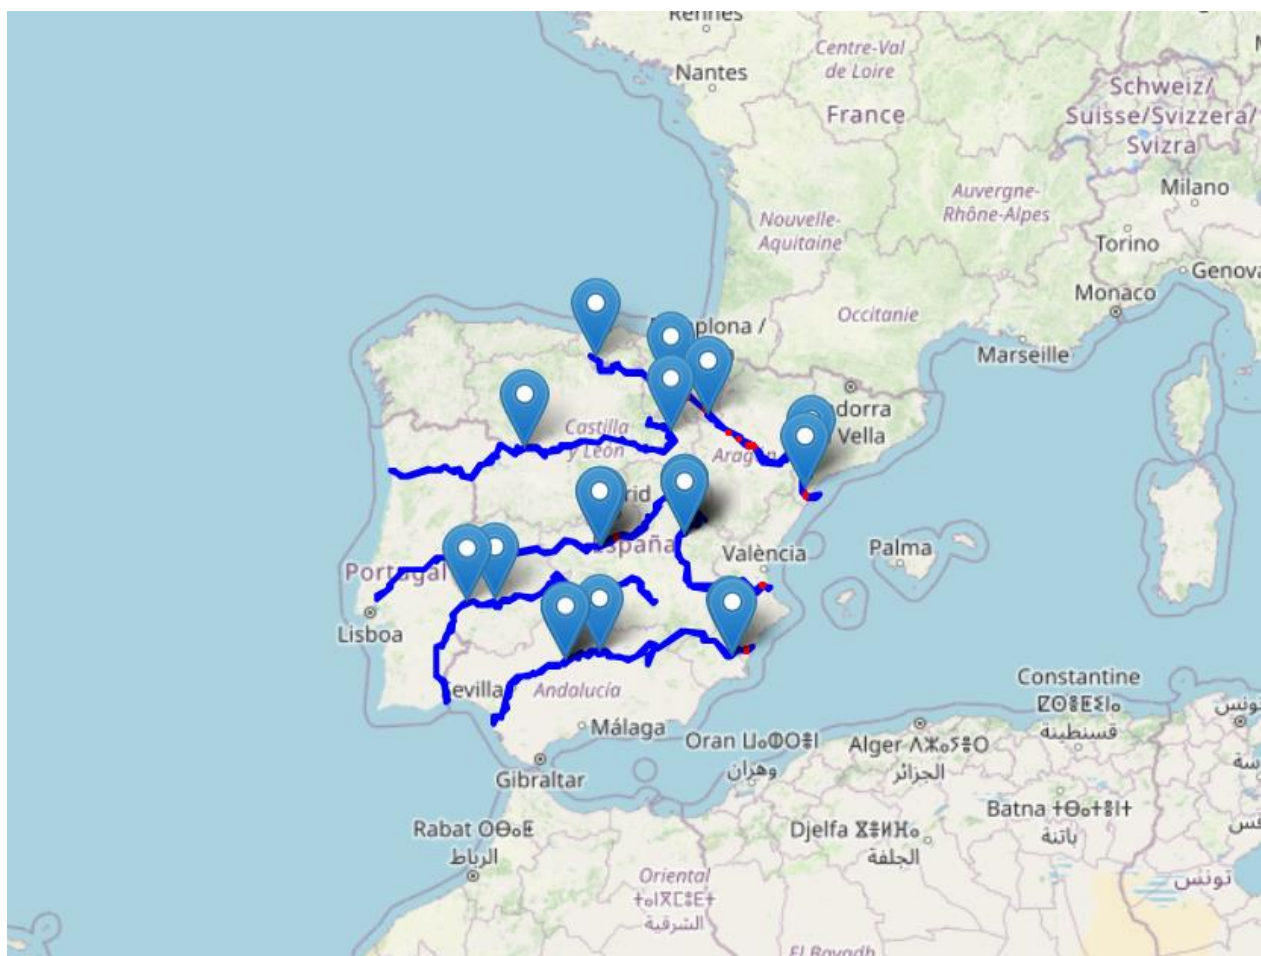


Figura 27. Mapa final de hospitales y autopistas afectadas.

En rojo se pueden ver todas las zonas de autopistas que quedarían inundadas por el desbordamiento y los puntos marcan los distintos hospitales afectados por el desbordamiento de los principales ríos de España.

Se integra un control de capas utilizando ‘LayerControl’ de Folium, que permite a los usuarios alterar la visualización de diferentes capas de datos, proporcionando una herramienta interactiva que enriquece la experiencia del usuario y facilita un análisis detallado de los datos presentados. Finalmente el mapa se muestra en la interfaz de usuario de Jupyter Notebook, donde puede ser interactuado, explorado y utilizado como herramienta de presentación o análisis. Además, este mapa puede ser fácilmente compartido o incorporado en documentos y presentaciones, maximizando su utilidad y accesibilidad.

Se contabilizó el número de municipios dentro de las áreas afectadas, que fueron 651, y se sumó la población residente en estas zonas bajo cada escenario de buffer de 1000 m, resultando en 6.445.486 personas afectadas. Estos cálculos proporcionan una dimensión del impacto humano y administrativo potencial, permitiendo una evaluación cuantitativa del riesgo asociado a cada escenario de inundación y sus afecciones a las infraestructuras críticas de la salud y el transporte.

Archivo

El análisis completo y detallado está disponible en el archivo:

Geoanálisis_red_hidrografica_municipios.ipynb.

4.3.2. Geoanálisis de depósitos y población.

La importación de las librerías que se van a utilizar en nuestro ambiente de Jupyter Notebook es con diferencia uno de los pasos más importantes porque si no tenemos dichas librerías no vamos a poder utilizar los distintos algoritmos para realizar nuestros análisis a nuestras capas o datos presentes. En este análisis las librerías son las siguientes en cada uno de los análisis las librerías pueden variar.

```
1 import geopandas as gpd
2 from shapely.geometry import Point
3 from scipy.spatial import cKDTree
4 import matplotlib.pyplot as plt
5 import folium
6 from scipy.spatial import cKDTree
```

Figura 28. Importación de librerías.

Prosiguiendo con el habitual procedimiento de los primeros pasos ahora es el momento de crear dos variables que van a guardar en memoria las rutas de los archivos con los que queremos trabajar. Para posteriormente cargar las capas de municipios y depósitos de combustible con la función de pandas `gpd.read_file` y mostraremos la información que contienen ambas capas para hacernos una idea de los datos que tenemos y con los cuales podemos trabajar.

```

1 # Rutas de los archivos
2 ruta_municipios = r'C:\Users\mlain\anaconda3\envs\
    ambiente_geopandas_rasterio\Capas_IC\Municipios\
    audes2010-mun\shp\audes2010-mun.shp'
3 ruta_depositos = r'C:\Users\mlain\anaconda3\envs\
    ambiente_geopandas_rasterio\Capas_IC\Depositos_comb
    \Depositos_combustible.geojson'
4
5 # Cargar las capas de municipios y depósitos.
6 capa_municipios = gpd.read_file(ruta_municipios)
7 capa_depositos = gpd.read_file(ruta_depositos)
8
9 # Mostrar información de las capas cargadas
10 print("Información de la capa de municipios:")
11 print(capa_municipios.head())
12
13 print("\nInformación de la capa de depósitos:")
14 print(capa_depositos.head())

```

Figura 29. Carga de los datos y visualización de información.

En las siguientes (figuras 30 y 3) se observan los datos que contienen tanto la capa de municipios como la capa de depósitos de combustible.

Información de la capa de municipios:

	CODINE	NOMBRE	KM2	HBT	DENSIDAD	CP	PROVIN	CA	AUTONOM	\
0	15044	Mañón	82.21	1622	19.73	15	Coruña, A	12	Galicia	
1	15901	Cariño	47.19	4590	97.27	15	Coruña, A	12	Galicia	
2	27064	Vicedo, O	75.96	2011	26.47	27	Lugo	12	Galicia	
3	15061	Ortigueira	209.60	7150	34.11	15	Coruña, A	12	Galicia	
4	15022	Cedeira	46.20	7465	161.58	15	Coruña, A	12	Galicia	

	CU	...	TMA	N_CU	N_AU	N_SAU	CAPITAL	\
0	None	...	None	None	None	None	Caión (Mañón) (Santa Marija)	
1	None	...	None	None	None	None	Cariño (Cariño) (San Bartolomeu)	
2	None	...	None	None	None	None	Vicedo, O (O Vicedo) (Santo Estevo)	
3	None	...	None	None	None	None	Ortigueira (Ortigueira) (Santa Marta)	
4	None	...	None	None	None	None	Cedeira (Cedeira) (Santa Marija do Mar)	

	FECHA	SHAPEID	COL_CU	COL_AU	\
0	None	0	None	None	
1	None	1	None	None	
2	None	2	None	None	
3	None	3	None	None	
4	None	4	None	None	

	geometry
0	MULTIPOLYGON (((-7.69001 43.79189, -7.69016 43...
1	MULTIPOLYGON (((-7.87015 43.78124, -7.87027 43...
2	MULTIPOLYGON (((-7.63219 43.75653, -7.63229 43...
3	MULTIPOLYGON (((-7.75043 43.74834, -7.75049 43...
4	MULTIPOLYGON (((-7.97620 43.71961, -7.97632 43...

Figura 30. Datos que contienen nuestra capa municipios.

Información de la capa de depósitos:

	id	x	y	wkid	geometry
0	1	-0.002965	39.947566	102100	POINT (-0.00296 39.94757)
1	2	-0.004067	39.949244	102100	POINT (-0.00407 39.94924)
2	3	-0.003571	39.949956	102100	POINT (-0.00357 39.94996)
3	4	-0.000357	39.944986	102100	POINT (-0.00036 39.94499)
4	5	-0.001231	39.946788	102100	POINT (-0.00123 39.94679)

Figura 31. Datos que contiene capa depósitos.

Los subsecuentes pasos fueron establecer el CRS que vamos a utilizar para nuestro proyecto que es el EPSG: 25830. Esta parte se llevó a cabo realizando cargando las capas primero y posteriormente cambiando a cada capa con el atributo .crs el sistema de coordenadas. En la siguiente figura se muestran los pasos necesarios para la consecución de este objetivo.

```

1 # Cargar la capa de municipios sin asignar un CRS
2 capa_municipios = gpd.read_file(ruta_municipios)
3
4 # Establecer el CRS para la capa de municipios
5 capa_municipios.crs = 'EPSG:4326' # Esto es un
   ejemplo, debes asignar el CRS correcto de tus datos
6
7 # Transformar la capa de municipios al CRS deseado
8 capa_municipios = capa_municipios.to_crs('EPSG:25830')
9
10 # Cargar la capa de depósitos sin asignar un CRS
11 capa_depositos = gpd.read_file(ruta_depositos)
12
13 # Establecer el CRS para la capa de depósitos
14 capa_depositos.crs = 'EPSG:4326' # Esto es un ejemplo
   , debes asignar el CRS correcto de tus datos
15
16 # Transformar la capa de depósitos al CRS deseado
17 capa_depositos = capa_depositos.to_crs('EPSG:25830')

```

Figura 32. Establecer el crs EPSG: 25830 para las capas.

Posteriormente se verificaron los CRS y se comprobó que estaban los dos en el CRS seleccionado para desarrollar nuestro análisis.

```

1 # Verificar el CRS de la capa de municipios y de
   depositos.
2 print("CRS de la capa de municipios:", capa_municipios
   .crs)
3 print("CRS de la capa de depositos :", capa_depositos.
   crs)

```

```

1 CRS de la capa de municipios: EPSG:25830
2 CRS de la capa de depositos : EPSG:25830

```

Figura 33. Verificación del crs de las capas.

El siguiente paso en el desarrollo de nuestro análisis de los depósitos y sus afecciones en la población fue calcular los centroides de los depósitos y de los municipios ya que en nuestro caso para calcular las distancias de los depósitos a los municipios fue el método más apropiado de varios métodos que se intentaron llevar a cabo. El código para obtener estos cálculos puede observarse en la (figura 34).

```

1  # Calcular los centroides de los polígonos
2  centroides_mun = capa_municipios.geometry.centroid
3  centroides_depo = capa_depositos.geometry.centroid
4
5  # Obtener las coordenadas X de los centroides
6  coordenadas_x_mun = centroides_mun.x
7  coordenadas_y_mun = centroides_mun.y
8  coordenadas_x_depo = centroides_depo.x
9  coordenadas_y_depo = centroides_depo.y
10 # Imprimir las coordenadas X
11 print(f'Estas son las coordenadas x municipios: ',
12       coordenadas_x_mun)
13 print(f'Estas son las coordenadas y municipios: ',
14       coordenadas_y_mun)
15 print(f'Estas son las coordenadas x de depósitos: ',
16       coordenadas_x_depo)
17 print(f'Estas son las coordenadas y de depósitos: ',
18       coordenadas_y_depo)

```

Figura 34. Cálculo de los centroides de municipios y depósitos.

Posteriormente a obtener los centroides de cada uno de los elementos de depósitos y de municipios se desarrolló una función en Python que calcula las distancias mínimas entre los centroides de los depósitos y municipios utilizando un árbol espacial (cKDTree).

```

1  def distancia_entre_depositos_y_municipios(
2      depositos_centroides_x, depositos_centroides_y,
3      municipios_centroides_x, municipios_centroides_y):
4      # Construir árbol espacial para los centroides de
5      # los municipios
6      municipios_centroides = list(zip(
7          municipios_centroides_x,
8          municipios_centroides_y))
9      municipios_tree = cKDTree(municipios_centroides)
10
11     distancias = [] # Lista para almacenar las
12     # distancias calculadas
13
14     # Iterar sobre los depósitos
15     for depo_x, depo_y in zip(depositos_centroides_x,
16                               depositos_centroides_y):
17         # Encontrar el índice del municipio más
18         # cercano al depósito
19         nearest_idx = municipios_tree.query((depo_x,
20                                              depo_y))[1]
21
22         # Calcular la distancia entre el depósito y el
23         # municipio más cercano
24         distancia = ((depo_x - municipios_centroides_x
25                       [nearest_idx])**2 + (depo_y -
26                       municipios_centroides_y[nearest_idx])**2)
27         **0.5
28         distancias.append(distancia) # Añadir la
29         # distancia a la lista
30
31     return distancias

```

Figura 35. Función distancias mínimas y creación árbol espacial.

Se construye un árbol espacial donde se combinan las coordenadas X e Y de los municipios en una lista de tuplas y se crea un árbol espacial cKDTree a partir de las coordenadas de los municipios para realizar búsquedas eficientes de los vecinos más cercanos. Para ello se crea una lista vacía de distancias para almacenar las distancias calculadas entre cada depósito y los municipios más cercanos.

Mediante esta función `nearest_idx = municipios_tree.query((depo_x, depo_y))[1]` para cada depósito, se encuentra el índice del municipio más cercano utilizando el árbol espacial `municipios_tree`. Después se calculan las distancias $\text{distancia} = ((\text{depo_x} - \text{municipios_centroides_x}[\text{nearest_idx}])**2 + (\text{depo_y} - \text{municipios_centroides_y}[\text{nearest_idx}])**2)**0.5$ después se almacenan las distancias

```

1  # Suponiendo que tienes las coordenadas de los
   centroides en estas variables
2  # coordenadas_x_depo, coordenadas_y_depo,
   coordenadas_x_mun, coordenadas_y_mun
3  distancias = distancia_entre_depositos_y_municipios(
   coordenadas_x_depo, coordenadas_y_depo,
   coordenadas_x_mun, coordenadas_y_mun)
4
5  # Añadir la lista de distancias al dataframe de depó
   sitos
6  capa_depositos['distancia_municipio_mas_cercano'] =
   distancias
7
8  if 'distancia_municipio_mas_cercano' in capa_depositos
   .columns:
9      print("La columna 'distancia_municipio_mas_cercano
   ' existe en el DataFrame.")
10     print(capa_depositos['
   distancia_municipio_mas_cercano'].head(20))
11 else:
12     print("La columna 'distancia_municipio_mas_cercano
   ' no existe en el DataFrame.")

```

Figura 36. Añadir la lista de distancias al DataFrame de Depósitos.

Para finalizar se muestran los resultados obtenidos en mapas mediante la biblioteca Matplotlib para que podáis observar cómo quedan los mapas con otra biblioteca. El código de la (figura 36) muestra la secuencia de operaciones que realiza varios pasos para calcular y visualizar la población afectada por distintos buffers alrededor de los depósitos.

Se inicializa este código con la creación de un diccionario vacío que será el que almacénalos resultados para cada buffer de 1 km a 5km. Se iteran a través de los valores 1, 2, 3, 4,5 que representan los buffers y se selecciona la geometría del buffer correspondiente y se establece como la geometría activa en el GeoDataFrame `capa_depositos`. Se realiza la intersección geoespacial entre depositos y municipios con la función `gpd.overlay` con el parámetro `intersection` y esto crea las zonas de afectados que contiene las zonas de los municipios y los depósitos se solapan. Para finalizar se calcula la suma de la población afectada dentro del buffer actual y se almacena en el diccionario creado anteriormente. Finalmente se genera una visualización clara y detallada de las áreas afectadas por diferentes buffers alrededor de los depósitos y muestra la población impactada en cada caso.

```

1  # Diccionario para almacenar la población afectada por
    cada buffer
2  poblacion_por_buffer = {}
3
4  for i in range(1, 6):
5      # Seleccionar la geometría de interés, es decir,
        cada buffer de 1 km a 5 km
6      buffer_actual = f'buffer_{i}km'
7      capa_depositos = capa_depositos.set_geometry(
        buffer_actual)
8
9      # Realizar la intersección con la capa de
        municipios
10     zonas_afectadas = gpd.overlay(capa_municipios,
        capa_depositos, how='intersection')
11
12     # Calcular la población afectada en el rango
        actual
13     if 'HBT' in zonas_afectadas.columns:
14         poblacion_por_buffer[buffer_actual] =
            zonas_afectadas['HBT'].sum()
15     else:
16         poblacion_por_buffer[buffer_actual] = 0
17         print(f"La columna 'HBT' no se encuentra en
            los datos de los municipios para el buffer
            {buffer_actual}.")
18
19     # Visualización
20     for i in range(1, 6):
21         buffer_actual = f'buffer_{i}km'
22         fig, ax = plt.subplots(figsize=(10, 10))
23         capa_municipios.plot(ax=ax, color='white',
            edgecolor='black')
24         capa_depositos.set_geometry(buffer_actual).plot(ax
            =ax, color='red', alpha=0.5, label=f'Buffer de
            {i} km alrededor de depósitos')
25         plt.legend()
26         plt.title(f'Zonas afectadas por el buffer de {i}
            km y población impactada: {poblacion_por_buffer
            [buffer_actual]} personas')
27         plt.show()

```

Figura 37. Código para crear mapas zonas afectadas por las infraestructuras crítica de depósitos y sus afecciones en la población.

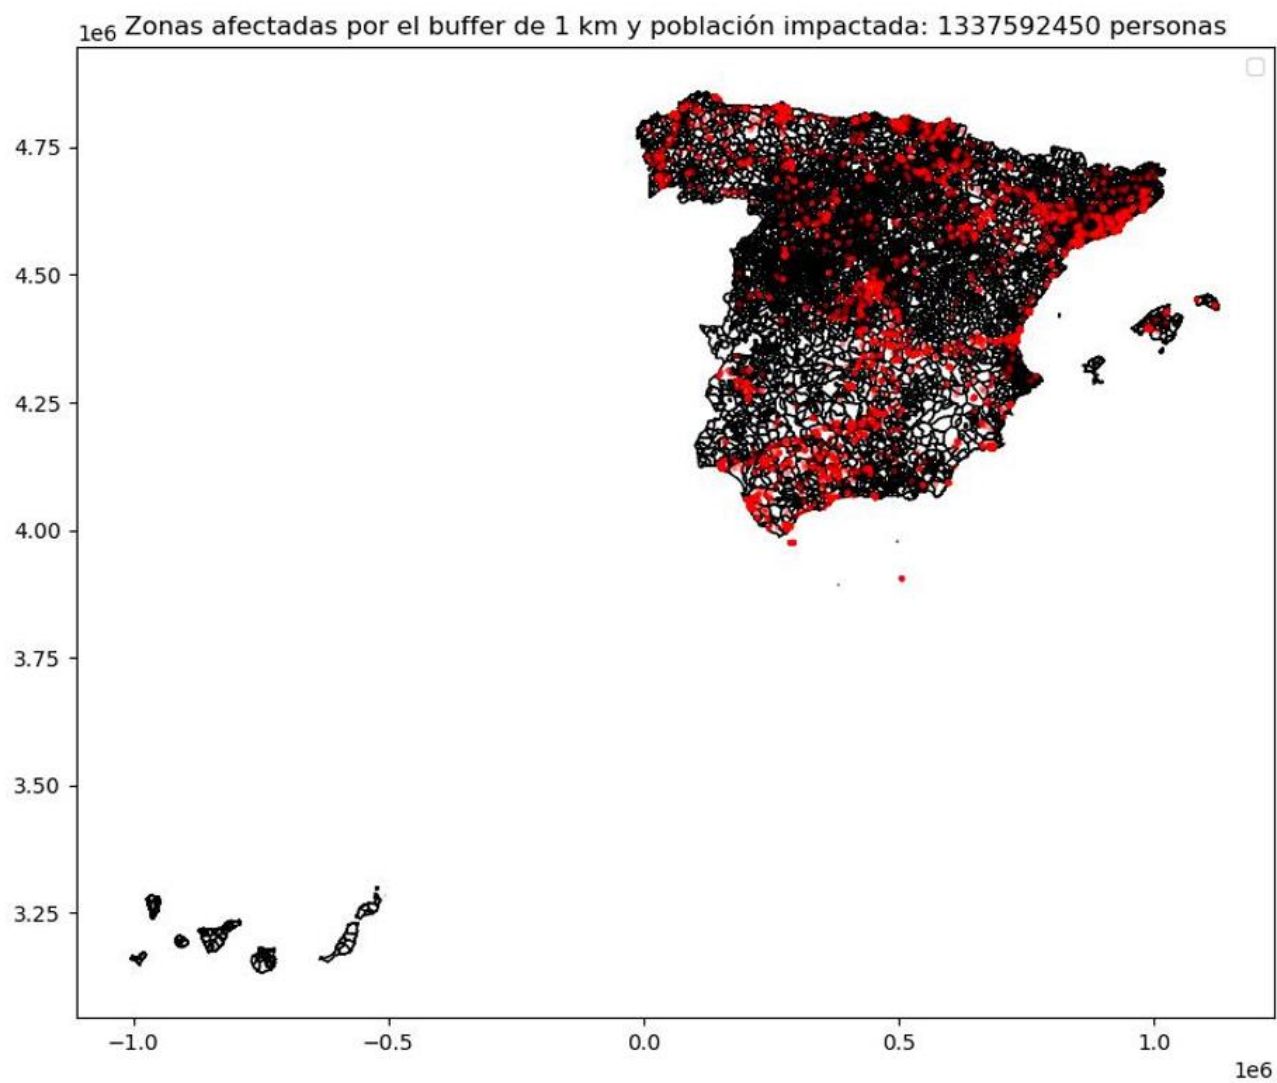


Figura 38. Mapa zonas afectadas y población por buffer de 1km.

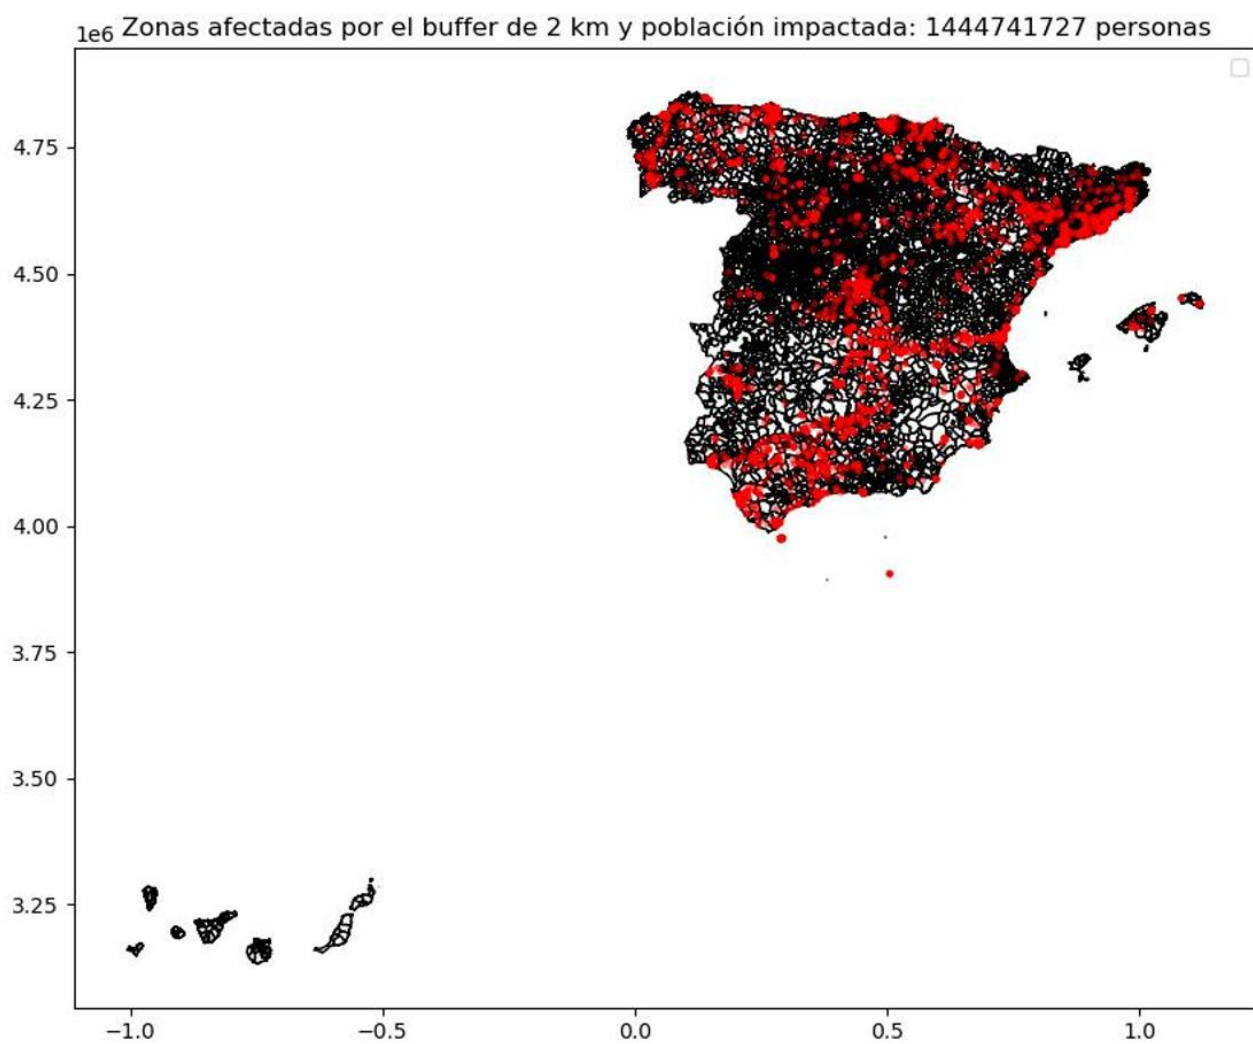


Figura 39. Mapa zonas afectadas y población por buffer de 2 km.

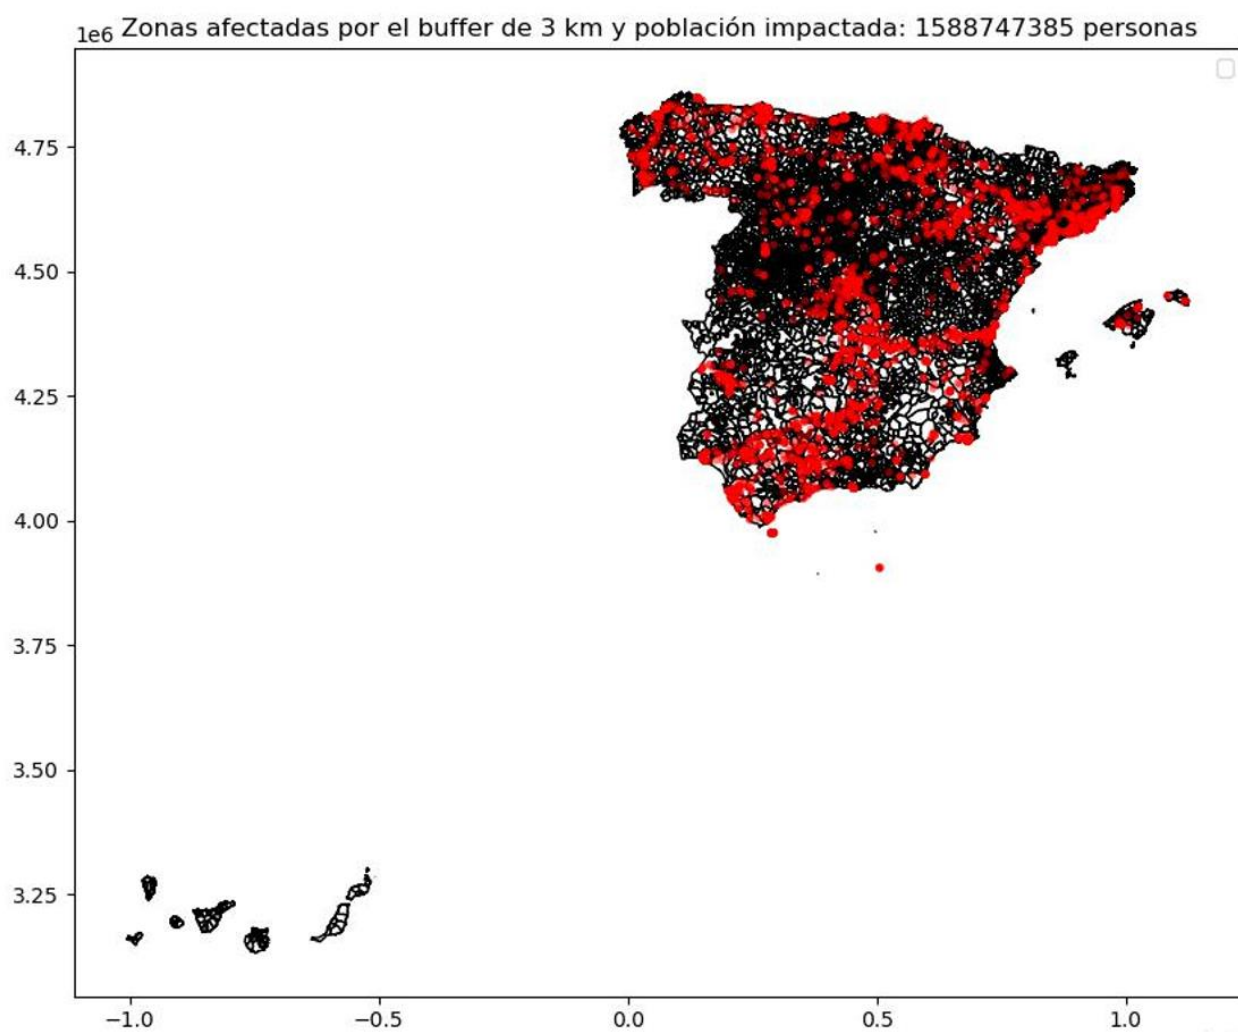


Figura 40. Mapa zonas afectadas y población por buffer de 3 km.

1e6 Zonas afectadas por el buffer de 4 km y población impactada: 1722643575 personas

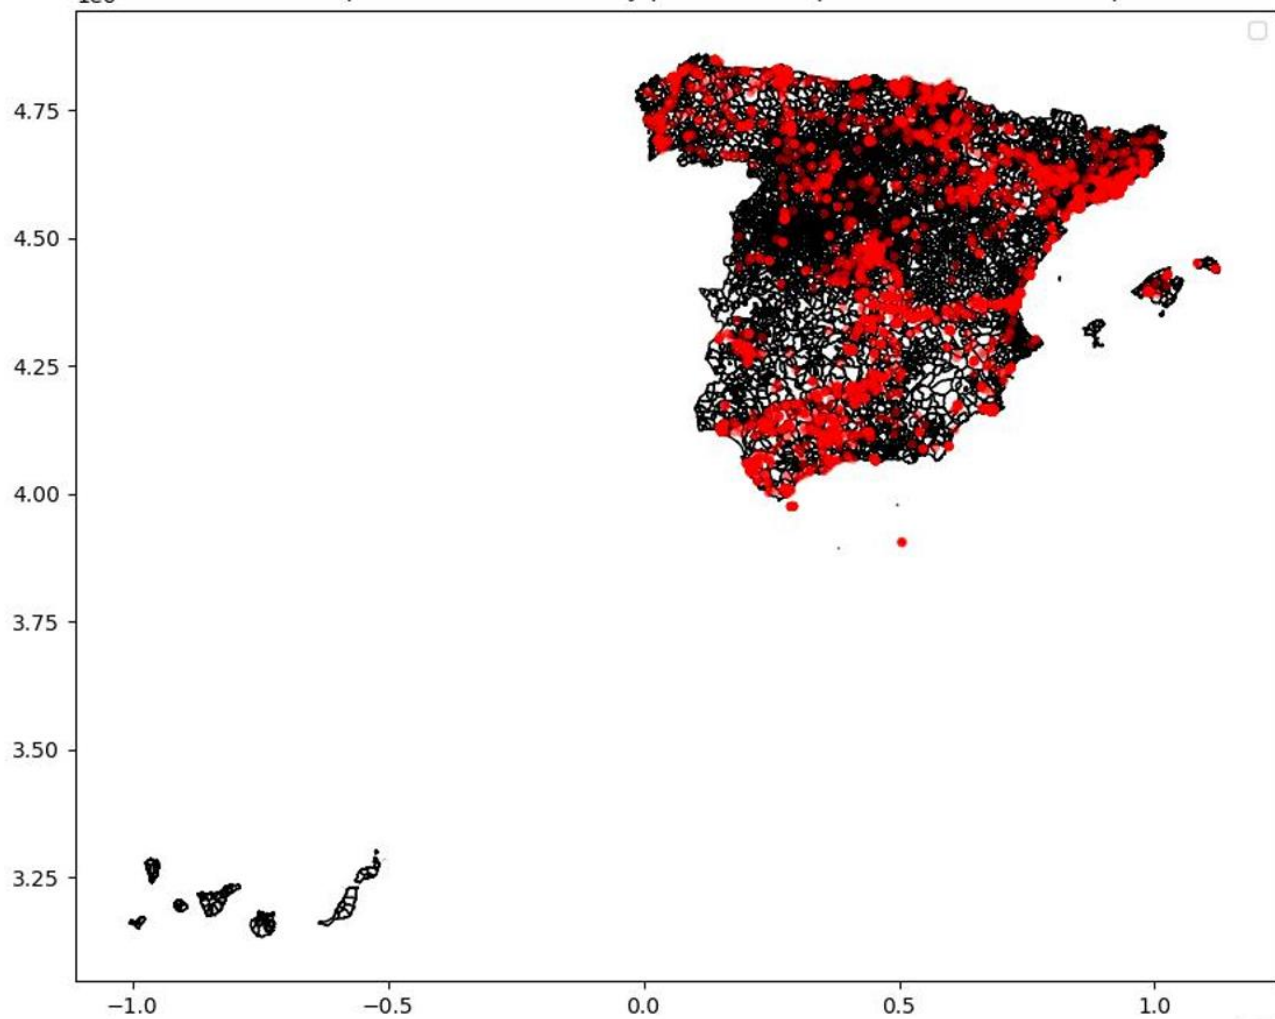


Figura 41. Mapa zonas afectadas y población por buffer de 4 km.

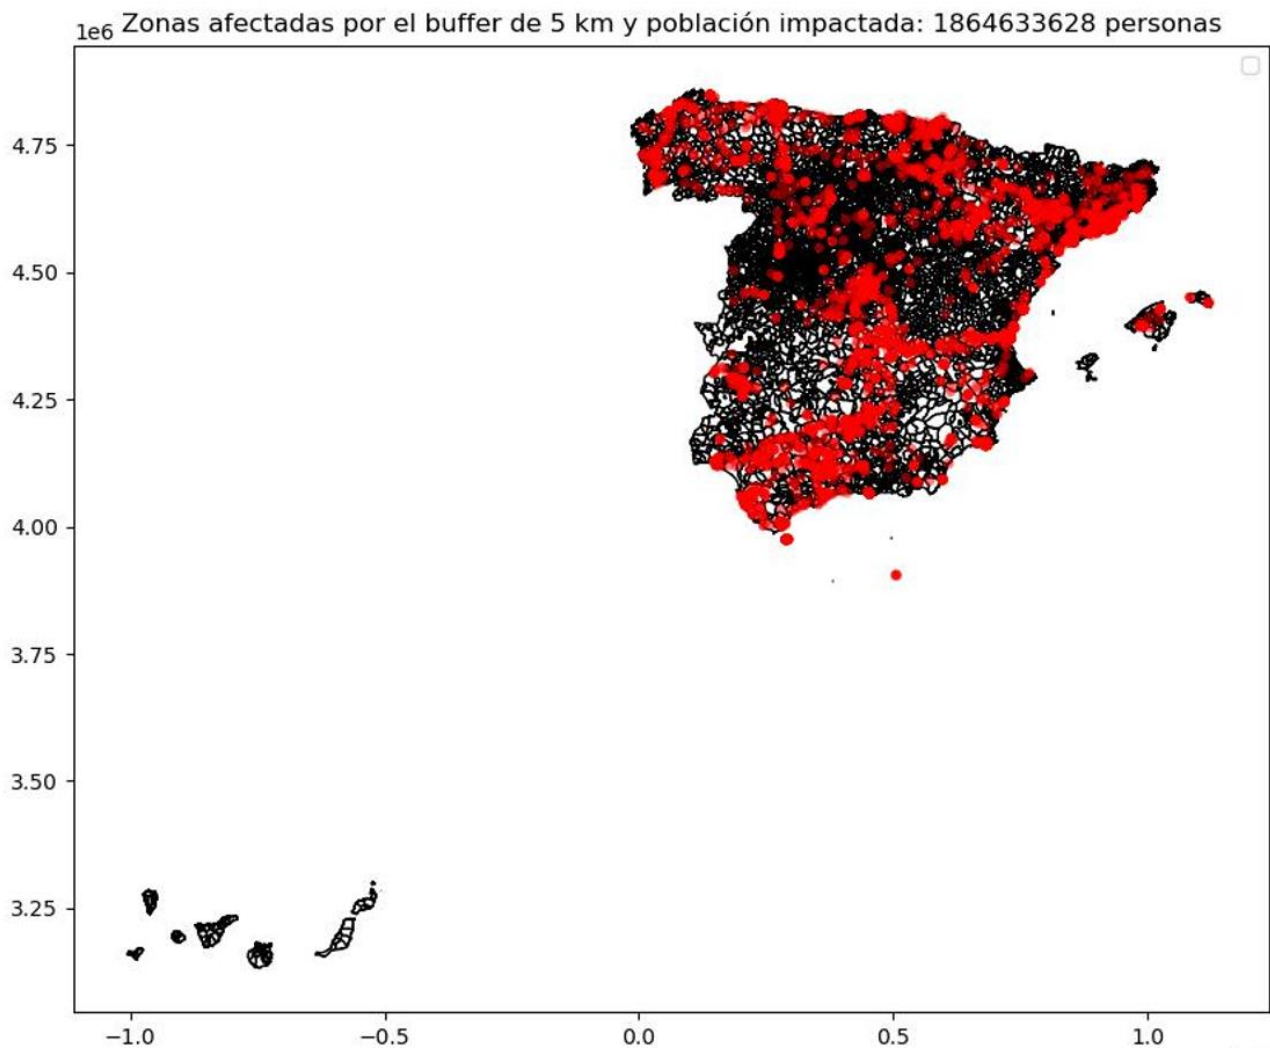


Figura 42. Mapa zonas afectadas y población por buffer de 5 km.

4.3.3. Geoanálisis de la cobertura de hospitales en municipios.

El objetivo principal de este análisis es conocer los datos presentes en ambas capas y aprender por otro lado el uso de las distintas herramientas que poseen las librerías de Python que vamos a utilizar en nuestro análisis final de obtener zonas de riesgo por afectados de las combinaciones de diferentes infraestructuras.

En este caso, vamos a evaluar la accesibilidad y distribución de los hospitales en relación con los municipios en España. Se pretenden identificar áreas con baja cobertura hospitalaria y municipios que podrían beneficiarse de una mejor planificación de los recursos hospitalarios.

Las primeras líneas de código son siempre las mismas, la importación de todos aquellos algoritmos que se van a utilizar para cargar, examinar, analizar, transformar y finalmente visualizar los resultados.

```

1  # Importar las librerías necesarias para el análisis.
2  import geopandas as gpd
3  import pandas as pd
4  import folium
5  from scipy.spatial import cKDTree
6  import matplotlib.pyplot as plt
7  import numpy as np
8  import matplotlib.pyplot as plt
9  import folium
10 from folium.plugins import MarkerCluster, HeatMap

```

Figura 43. Importación librerías necesarias para Geoanálisis de la cobertura de hospitales en municipios.

Seguidamente después de importar las librerías se crean las variables que encapsulan en memoria las rutas de nuestros archivos con el ya nombrado `gpd_read_file`.

```

1  # Carga de datos geoespaciales
2  hospitales = gpd.read_file(r'C:\Users\mlain\anaconda3\
    envs\ambiente_geopandas_rasterio\Capas_IC\
    Hospitales\hospitales.geojson')
3  municipios = gpd.read_file(r'C:\Users\mlain\anaconda3\
    envs\ambiente_geopandas_rasterio\Capas_IC\
    Municipios\audes2010-mun\shp\audes2010-mun.shp')

```

Figura 44. Cargar los datos mediante la función de geopandas `gpd.read_file`.

Seguidamente se transforman al sistema de coordenadas óptimo para nuestra zona de estudio que es el EPSG: 25830 con el cual podemos obtener cálculos precisos de las distancias es una de las múltiples ventajas de este CRS.

```

1  municipios = municipios.to_crs("EPSG:25830")
2  hospitales = hospitales.to_crs("EPSG:25830")
3  print(municipios.crs)
4  print(hospitales.crs)

```

Figura 45. Utilización de la función `to_crs` para transformar coordenadas al sistema EPSG: 25830.

Con las siguientes líneas de código fue observar que tipo de datos presentaban nuestras capas para posteriormente saber que procesos tenemos que seguir para tratarlas de la manera correcta.

```

1 print(municipios.geometry.head())
2 print(hospitales.geometry.head())
3 print(municipios.head())
4 print(hospitales.head())

```

Figura 46. Líneas de código para visualizar los tipos de datos que presentan dichas capas.

El subsecuente pasó trato de calcular los centroides de los hospitales que como ya estaban en tipo punto solo se hizo una verificación para confirmar que los datos se encontraran en esa geometría y se hizo el mismo proceso pero ahora con los municipios que en este caso sí que era de tipo polígono por lo tanto se tuvo que crear una geoserie llamada en GeoPandas una columna con todos los valores de los centroides de todos los municipios. Posteriormente se extraen las coordenadas x e y para los centroides y esto se hace mediante la librería NumPy que es para trabajar con datos tabulares se crea una lista que englobara los valores de las geometrías X e Y de cada capa. Para finalmente crear un árbol KD para incrementar la velocidad de procesamiento de estas operaciones de búsqueda del hospital más cercano al municipio más cercano.

```

1 # Calcular los centroides de los hospitales si no está
  # representados por puntos
2 if not hospitales.geometry.iloc[0].geom_type == 'Point':
3     hospitales['centroid'] = hospitales.geometry.
      centroid
4 else:
5     hospitales['centroid'] = hospitales.geometry
6
7 # Asegúrate de que los municipios también tienen una
  # columna de centroides
8 municipios['centroid'] = municipios.geometry.centroid
9
10 # Extraer las coordenadas x e y para los centroides de
  # los hospitales y municipios
11 coords_hospitales = np.array(list(hospitales['centroid']
  # ].apply(lambda geom: (geom.x, geom.y))))
12 coords_municipios = np.array(list(municipios['centroid']
  # ].apply(lambda geom: (geom.x, geom.y))))
13
14 # Crear el árbol KD para los hospitales
15 arbol_kd = cKDTree(coords_hospitales)
16
17 # Consultar el árbol KD para cada municipio y
  # encontrar la distancia al hospital más cercano
18 distancias, _ = arbol_kd.query(coords_municipios)
19
20 # Asignar las distancias al GeoDataFrame de municipios
21 municipios['distancia_hospital_mas_cercano'] =
  distancias

```

Figura 46. Código para calcular los centroides de los hospitales y municipios, crear el árbol y consultar la distancia al hospital más cercano.

Posteriormente se quiso saber cuál era la distancia máxima y mínima desde cualquier municipio de España al hospital más cercano o más alejado. Esto se comprobó mediante dos simples líneas de código que fueron las siguientes.

```
1 # Asegurarse de que las distancias reflejan los cálculos basados en los centroides
2 print("Comprobando los valores de distancia al hospital más cercano (calculados a partir de los centroides):")
3 print(f"Distancia mínima al hospital más cercano: {municipios['distancia_hospital_mas_cercano'].min()} metros")
4 print(f"Distancia máxima al hospital más cercano: {municipios['distancia_hospital_mas_cercano'].max()} metros")
```

Figura 47. Comprobar la distancia mínima al hospital más cercano y la distancia máxima.

Los resultados de los valores de distancia mínima y máxima al hospital más cercano calculados a partir de los centroides fueron:

La distancia mínima es 216 metros esto indica que el municipio más cercano a un hospital está a solo metros de distancia, lo cual es posible en áreas urbanas donde los hospitales están más concentrados.

La distancia máxima es aproximadamente 96 km este valor muestra que el municipio con el hospital a más distancia está a unos 100 kilómetros. Aunque esto pueda parecer una distancia considerable, es posible en regiones rurales o de alta montaña donde los hospitales normalmente están en ciudades y estos pueblos se encuentran a kilómetros de distancia de ellas.

Se quiso obtener distintos estadísticos descriptivos mediante una línea de código como se observa en la figura 48.

```
1 # Análisis Estadístico Adicional.
2 # Estadísticas Descriptivas
3 estadisticas = municipios['distancia_hospital_mas_cercano'].describe()
4 print(estadisticas)
```

Figura 48. Con la función .describe () se obtienen estos estadísticos descriptivos de la columna deseada.

count	8200.000000
mean	24729.894926
std	14872.766458
min	216.529619
25%	12919.613488
50%	22668.246246
75%	34304.137651
max	96241.446637

Figura 49. Estadísticos descriptivos de la columna distancias_hospital más cercano desde cada municipio.

Para una mejor visualización de los datos de la distribución de las distancias se desarrolló un histograma mediante la librería Matplotlib (figura 50).

```

1 # Histograma de Distancias.
2 # Histograma de las distancias
3 plt.figure(figsize=(10, 6))
4 plt.hist(municipios['distancia_hospital_mas_cercano'],
5         bins=50, color='blue', alpha=0.7)
6 plt.title('Distribución de Distancias a Hospitales Más
7 Cercanos')
8 plt.xlabel('Distancia (metros)')
9 plt.ylabel('Número de Municipios')
10 plt.grid(True)
11 plt.show()

```

Figura 50. Código para crear el histograma de distribución de las distancias al hospital más cercano.




Figura 51. Histograma distribución distancias del municipio al hospital más cercano.

Mediante el histograma de la distribución de las distancias a los hospitales más cercanos se puede apreciar que la gran mayoría de los hospitales se encuentra desde los 10 - 40 kilómetros con algunas excepciones. La presencia de municipios con acceso muy cercano y otros con acceso más distante sugiere una distribución geográfica variada de los hospitales. Esta distribución es típica de países con áreas urbanas densamente pobladas como las zonas de la costa española o Madrid y extensas zonas rurales como todo el centro de España con áreas montañosas como los Pirineos, Sistema Central ...

Este análisis tiene implicaciones para la Planificación de Servicios de Salud debido a que toda estos datos son cruciales para los planificadores de servicios de salud y los responsables políticos. Mediante estos datos obtenidos se podrían identificar estar áreas con acceso deficiente para mejorar las infraestructuras críticas de salud de determinadas zonas rurales.

Seguidamente a este análisis se propuso obtener las distancias al segundo hospital más cercano y al tercero. Este proceso se volvió a desarrollar mediante consultas a los árboles KDTree.

```
1  # Realizar la consulta para obtener las distancias a
    los tres hospitales más cercanos
2  distancias, indices = arbol_kd.query(coords_municipios
    , k=3)
3  # Asignar las distancias al GeoDataFrame de municipios
4  municipios['distancia_primer_hospital'] = distancias
   [:, 0] # Distancia al hospital más cercano
5  municipios['distancia_segundo_hospital'] = distancias
   [:, 1] # Distancia al segundo hospital más cercano
6  municipios['distancia_tercer_hospital'] = distancias
   [:, 2] # Distancia al tercer hospital más cercano
7
8  # Verificar los primeros registros para asegurar que
    los datos se han añadido correctamente
9  municipios[['distancia_primer_hospital', '
    distancia_segundo_hospital', '
    distancia_tercer_hospital']].head()
```

Figura 52. Código para la obtención de las distancias la segundo y tercer hospital más cercano.

	distancia_primer_hospital	distancia_segundo_hospital	distancia_tercer_hospital
0	30192.902503	38615.070636	40717.851228
1	34434.418848	34539.620732	36655.285476
2	25326.251555	37343.289192	46759.437386
3	33850.234217	34542.109185	35737.333580
4	24465.212158	24508.437820	26793.870036

Figura 53. Resultados de las distancias al segundo y tercer hospital más cercano.

Para ir terminando con nuestro análisis se propuso un umbral de 50 kilómetros que serían todos aquellos municipios con un acceso insuficiente en términos de distancias al hospital más cercano. Este paso se desarrolló creando una Geoseries dentro de la capa de municipios que se nombró como acceso_insuficiente. Esta parte se desarrolló mediante una simple comparación de la columna distancia al primer hospital debe ser mayor al umbral de 50 kilómetros.

```

1 umbral_distancia = 50000 # 50 km
2 municipios['acceso_insuficiente'] = municipios['
    distancia_primer_hospital'] > umbral_distancia
3 # Filtrar los municipios con acceso insuficiente a
    hospitales
4 municipios_insuficientes = municipios[municipios['
    acceso_insuficiente']]
5
6 # Mostrar los municipios insuficientes
7 print("Municipios con acceso insuficiente a hospitales
    :")
8 print(municipios_insuficientes)

```

Figura 53. Código para obtener los municipios con acceso insuficiente.

Los cinco primeros municipios con acceso insuficiente son:

```

Municipios con acceso insuficiente a hospitales:
473          Boca de Hurgano
517          Villablino
577    Velilla del Rjo Carrión
579          Medina de Pomar
601          Uztarroze/Uztarroze

```

Figura 54. Municipios con acceso insuficiente.

Se finalizó el análisis mediante un mapa que se elaboró con la librería Matplotlib, con todos aquellos municipios con un acceso insuficiente a hospitales. En las siguientes (figuras 55, 56) se puede observar el código y el mapa que se obtuvo.

```
1  # Crear la figura y los ejes
2  fig, ax = plt.subplots(1, 1, figsize=(15, 10))
3
4  # Establecer una paleta de colores donde los
   municipios con acceso insuficiente se destaquen
   claramente
5  municipios.plot(column='acceso_insuficiente', ax=ax,
   legend=True,
6                  cmap='coolwarm', categorical=True,
   edgecolor='black')
7
8  # Añadir títulos y etiquetas
9  plt.title('Acceso a Hospitales en Municipios',
   fontsize=16)
10 ax.set_xlabel('Longitud', fontsize=14)
11 ax.set_ylabel('Latitud', fontsize=14)
12
13 # Mejorar la legibilidad de la leyenda
14 leg = ax.get_legend()
15 leg.set_bbox_to_anchor((1, 0.5))
16
17 # Añadir manualmente la etiqueta de la leyenda
18 legend = ax.get_legend()
19 legend.set_title("Acceso insuficiente a hospitales",
   prop={'size': 12})
20
21 # Guardar el mapa como archivo JPG
22 plt.savefig('acceso_hospitales_municipios.jpg', format
   ='jpg', dpi=300, bbox_inches='tight')
23
24 plt.show()
```

Figura 55. Código para crear el mapa con la biblioteca Matplotlib.

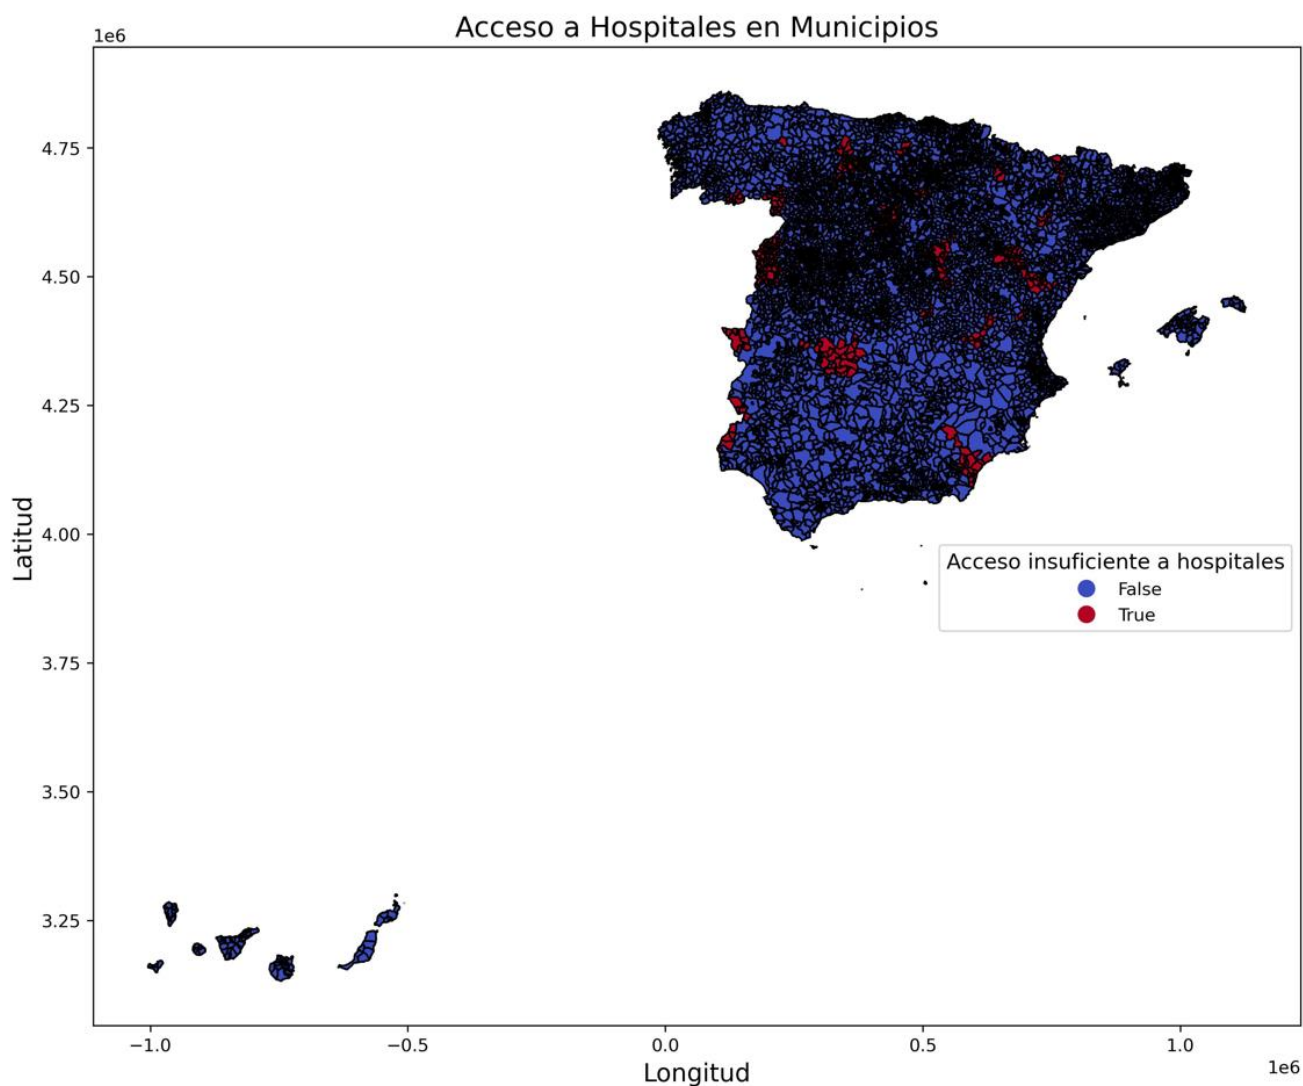


Figura 56. Mapa municipios con acceso insuficiente.

Para finalizar con este análisis se crearon unas tres líneas de código con las cuales pudimos obtener el número total de municipios, el número de municipios con acceso insuficiente y el porcentaje de municipios con acceso insuficiente.

```

1 num_municipios_total = len(municipios)
2 num_municipios_insuficientes = len(
3     municipios_insuficientes)
4 porcentaje_insuficiente = (
5     num_municipios_insuficientes / num_municipios_total
6     ) * 100
7
8 print(f"Número total de municipios: {
9     num_municipios_total}")
10 print(f"Número de municipios con acceso insuficiente:
11     {num_municipios_insuficientes}")
12 print(f"Porcentaje de municipios con acceso
13     insuficiente: {porcentaje_insuficiente:.2f}%")

```

Figura 57. Código para saber número de municipios con acceso insuficiente.

Número total de municipios: 8200
Número de municipios con acceso insuficiente: 496
Porcentaje de municipios con acceso insuficiente: 6.05%

Figura 58. Estadísticos obtenidos de municipios con acceso insuficiente.

Para dar por concluido este análisis se crearon unos rangos de distancias basados en los datos observados en el que se pueden apreciar en la figura 59. Posteriormente se crear un mapa de distancias a los hospitales más cercanos de cada uno de los municipios de España que se muestra en la figura 60.

```
1  # Definir nuevos rangos de distancia basados en los
    datos observados
2  bins = [0, 10, 20, 30, 40, 50, np.inf]
3  names = ['<10 km', '10-20 km', '20-30 km', '30-40 km',
    '40-50 km', '>50 km']
4
5  # Convertir la columna 'distancia_primer_hospital' a
    kilómetros si es necesario
6  municipios['distancia_primer_hospital'] = municipios['
    distancia_primer_hospital'].astype(float) / 1000 #
    Asumir que los datos están en metros
7
8  # Aplicar la categorización de los municipios según la
    distancia al hospital más cercano
9  municipios['categoria_distancia'] = pd.cut(municipios[
    'distancia_primer_hospital'], bins, labels=names)
10
11 # Contar municipios por categoría
12 categoria_counts = municipios['categoria_distancia'].
    value_counts()
13 print(categoria_counts)
```

Figura 59. Código para definir los rangos de distancias.

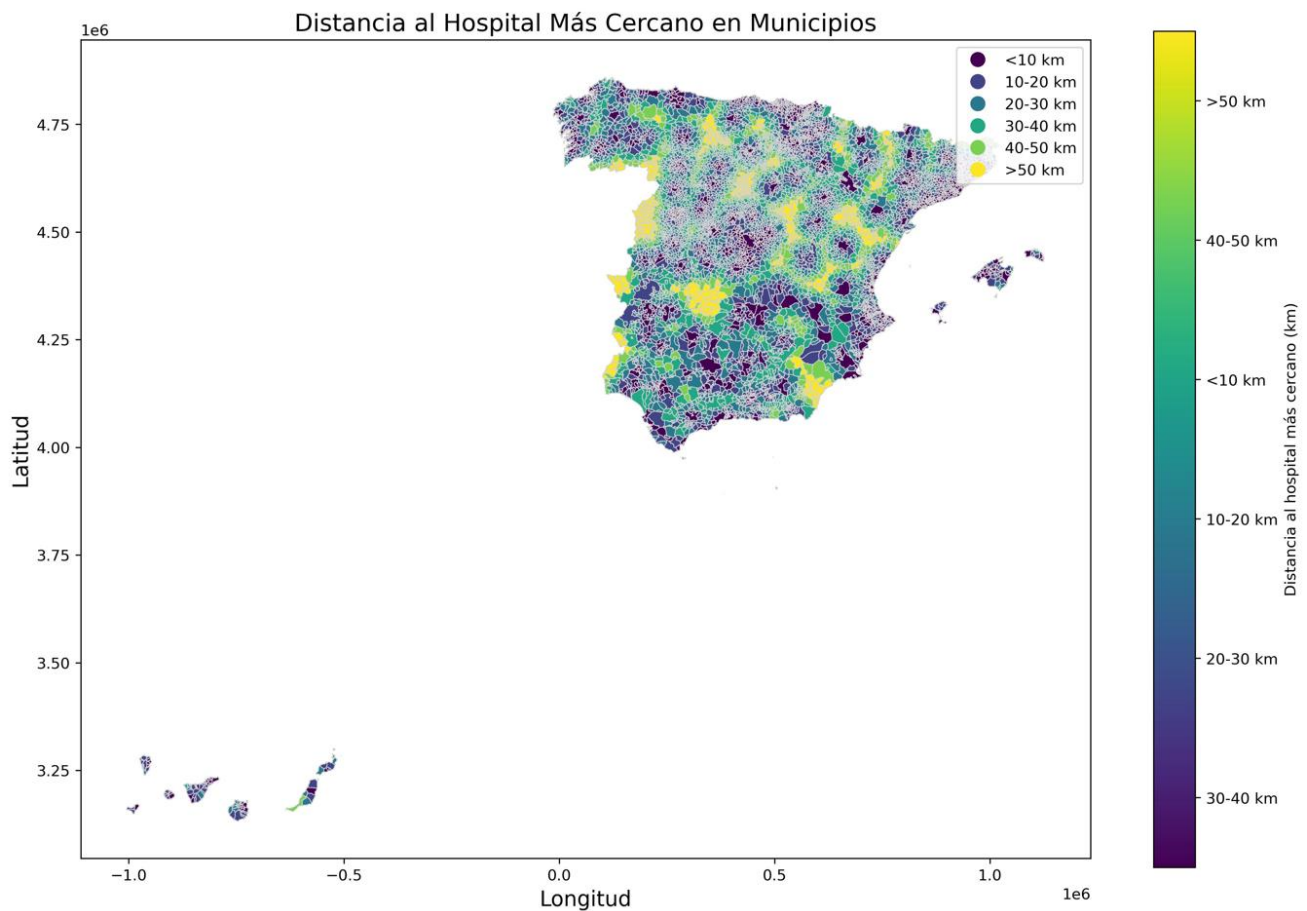


Figura 60. Mapa de distancias al hospital más cercano en España.

En la Figura 60 se visualiza el mapa final de distancias desde municipios a hospitales más cercanos, los resultados obtenidos como se ha hablando en párrafos anteriores es que en la mayoría de las zonas costeras las distancias a los hospitales son mínimas ya que son las zonas más densamente pobladas de España donde se localizan la gran mayoría de los hospitales. Luego tenemos ciertos municipios de la España vaciada donde las distancias se incrementan a más de 50 kilómetros. Estas regiones se encuentran en la provincia de Huesca, Teruel, Cáceres, Badajoz, Ciudad Real, Guadalajara, Zamora, Ourense, Segovia y Soria. Es en todas estas zonas es donde se debería de actuar para contrarrestar los efectos adversos de tener los hospitales a distancias superiores a 50 kilómetros lo que puede acarrear menos posibilidades de supervivencia en casos extremos de ataques al corazón, ataques cerebrovasculares donde un hospital cerca incrementa las posibilidades de supervivencia.

4.3.4. Geoanálisis de las líneas eléctricas y municipios.

Este análisis sobre las líneas eléctricas y los municipios tratar de descubrir cuáles son los municipios con deficiencias en este servicio de en líneas eléctricas de alta tensión las más importantes si quieres desarrollar la economía de tu región. Debido a que permiten la instalación de determinadas industrias que sin estas líneas de alta tensión no se podrían instalar debido a la alta demanda de energía que

necesitan. Se podrían añadir ciertas infraestructuras que fueran muy dependientes de la electricidad para evaluar su exposición a estas líneas.

Como en todos los análisis realizados con las distintas capas, el primer pasó es la importación de todas las librerías en nuestra primera celda del Jupyter Notebook. Lo cual se puede apreciar en la Figura X en este caso importamos librerías nuevas que no habíamos utilizado hasta ahora debido a en este se trabaja con geometrías tipo líneas.

```
1  # Estas son las librerías que utilizamos para el
    geoanálisis de líneas eléctricas y municipios.
2  import geopandas as gpd
3  from shapely.ops import triangulate
4  from shapely.geometry import Polygon
5  import matplotlib.pyplot as plt
6  import random
7  import folium
8  from shapely.ops import unary_union
9  from scipy.spatial import cKDTree
10 import numpy as np
11 from shapely.geometry import MultiLineString
```

Figura 61. Librerías importadas para el análisis de las líneas eléctricas.

Se prosigue con la carga de las capas correspondientes para el futuro análisis como se ha estado realizando hasta ahora y se les cambia el CRS al utilizado en todo nuestro estudio EPSG: 25830.

```
1  # Carga de la capa de líneas eléctricas desde un
    archivo GeoJSON
2  lineas_electricas = gpd.read_file(r'C:\Users\mlain\
    anaconda3\envs\ambiente_geopandas_rasterio\Capas_IC\
    Lineas_electricas\Lineas_electricas.geojson')
3
4  # Carga de la capa de municipios desde un archivo
    shapefile
5  municipios = gpd.read_file(r'C:\Users\mlain\anaconda3\
    envs\ambiente_geopandas_rasterio\Capas_IC\
    Municipios\audes2010-mun\shp\audes2010-mun.shp')

1  # Transformacion de CRS
2  municipios = municipios.to_crs("EPSG:25830")
3  lineas_electricas = lineas_electricas.to_crs("EPSG
    :25830")
```

Figura 62. Carga de las capas y transformación del crs.

Se prosigue con el análisis espacial para la extracción de los centroides de los municipios. Estos centroides representan la posición promedio de una figura geométrica como un polígono y son importantes debido a que ofrecen una forma simplificada de representar una figura compleja en lugar

de considerar cada punto en el borde de un polígono facilitando los cálculos y el análisis. Calcular distancias entre centroides es computacionalmente menos costoso que calcular distancias entre todos los puntos de dos figuras geométricas complejas. En muchos análisis espaciales como el que estamos realizando, la proximidad entre entidades geográficas es fundamental. Aunque el uso de centroides simplifica el análisis, mantiene una representación balanceada de la ubicación geográfica de las figuras. La función para desarrollar esta parte se visualiza en la siguiente figura 63.

```
1 # Calcular los centroides de los municipios:
2 municipios['centroide'] = municipios.geometry.centroid
```

Figura 63. Calculo de los centroides con geometry.centroid

Se vuelve a construir el árbol KD para crear puntos a partir de las líneas eléctricas para una mejor indexación y mayor velocidad en el cálculo de las distancias.

```
1 # Crear puntos a partir de las líneas eléctricas para
  construir el árbol KD:
2 # Convertir las líneas eléctricas en puntos
3 lineas_puntos = unary_union(lineas_electricas.geometry
  )
```

Figura 64. Convertir las líneas eléctricas en puntos.

Subsecuentemente se inicializa una lista para almacenar los puntos y se itera sobre cada línea de la red eléctrica para finalmente convertir los puntos en un array de NumPy para construir el árbol KD

```
1 # Inicializar una lista para almacenar los puntos
2 puntos = []
3
4 # Iterar sobre cada línea en el GeoDataFrame de líneas
  eléctricas
5 for linea in lineas_electricas.geometry:
6     if isinstance(linea, MultiLineString):
7         for segmento in linea:
8             puntos.extend([segmento.coords[0],
9                             segmento.coords[-1]])
10        else:
11            # Añadir el punto inicial y final de cada lí
              nea
12            puntos.extend([linea.coords[0], linea.coords
13                            [-1]])
14
15 # Convertir los puntos en un array de NumPy para
  construir el árbol KD
16 coords = np.array(puntos)
17
18 # Construir el árbol KD
19 arbol_kd = cKDTree(coords)
```

Figura 65. Iterar sobre cada línea de la red eléctrica.

El siguiente paso fue la definición de la función distancia_minima a las centroides incluyendo el árbol KD para el procesamiento de fluido de los cálculos.

```

1 def distancia_minima_centroide(centroide, arbol):
2     distancia, _ = arbol.query(centroide.coords[0], k
3         =1)
4     return distancia
5
6 # Aplicar la función para calcular la distancia más
7   corta desde los centroides al árbol KD
8 municipios['distancia_a_linea'] = municipios['
9   centroide'].apply(lambda x:
10      distancia_minima_centroide(x, arbol_kd))
11
12 # Mostrar los primeros 10 municipios y sus distancias
13   a la línea eléctrica más cercana
14 print(municipios[['NOMBRE', 'distancia_a_linea']].head
15       (10))

```

Figura 66. Definición de función de distancia mínima a los centroides.

	NOMBRE	distancia_a_linea
0	Mañón	2519.475039
1	Cariño	3182.644023
2	Vicedo, O	492.741862
3	Ortigueira	5546.090652
4	Cedeira	5257.714091
5	Xove	4131.693445
6	Cervo	9208.972903
7	Viveiro	2106.603567
8	Valdoviño	3253.547673
9	Burela	14425.603622

Figura 67. Resultados distancia líneas eléctricas a municipios.

Posteriormente se clasifican las distancias en distintos rangos para una mejor visualización en el mapa final.

```

1 def clasificar_por_rango(distancia):
2     if distancia < 3000:
3         return 'Cercano'
4     elif distancia < 6000:
5         return 'Medio'
6     else:
7         return 'Lejano'
8
9 # Aplicar la clasificación a cada municipio
10 municipios['rango_distancia'] = municipios['
11   distancia_a_linea'].apply(clasificar_por_rango)

```

Figura 68. Clasificar las distancias a líneas eléctricas en rangos.

Finalmente mediante la librería Matplotlib se crea el mapa final de los rangos de distancia a la que están cada uno de los municipios de España.

```
1 # Ajustar el tamaño del mapa
2 fig, ax = plt.subplots(1, 1, figsize=(20, 20)) # Tamaño
   # aumentado
3
4 # Colorear los municipios según el rango de distancia
5 municipios.plot(column='rango_distancia', ax=ax,
   legend=True,
6                 legend_kwds={'title': "Rango de
                               Distancia", 'loc': 'upper left', '
                               fontsize': 16, 'title_fontsize':
                               18},
7                 categorical=True, cmap='viridis')
8
9 # Eliminar la trama de las líneas eléctricas para
   # mejorar la visibilidad
10 # lineas_electricas.plot(ax=ax, color='red', linewidth
   # =1, label='Líneas Eléctricas') # Línea comentada
   # para no mostrar las líneas eléctricas
11
12 plt.title('Clasificación de Municipios por Distancia a
   Líneas Eléctricas', fontsize=20)
13 plt.xlabel('Longitud', fontsize=16)
14 plt.ylabel('Latitud', fontsize=16)
15
16 # Guardar el archivo en una ubicación específica
17 try:
18     plt.savefig(r'C:\Users\mlain\proyecto_practiva_tfm
   \mapa_municipios_distancia_lineas_electricas.
   png', dpi=300, bbox_inches='tight')
19     print("Archivo guardado exitosamente.")
20 except Exception as e:
21     print(f"Error al guardar el archivo: {e}")
22
23 plt.show()
```

Figura 69. Código para la creación del mapa mediante la librería de Matplotlib.

El mapa de la figura 68 representa la clasificación de los municipios de España según su distancia a las líneas eléctricas de alta intensidad utilizando tres categorías (Cercano, Medio y Lejano). Observando el mapa podemos advertir que las regiones costeras del Norte y Noroeste como Galicia, Asturias, Cantabria y el País Vasco presentan una alta concentración de municipios en los rangos cercanos y medio. Este se debe a la presencia de importantes infraestructuras industriales y urbanas que requieren suministro eléctrico robusto y confiable. Las zonas costeras de la región Mediterránea con Cataluña a la cabeza, Comunidad Valencia y Murcia también presentan altas tasas de densidad de municipios cercanos a líneas eléctricas de alta intensidad. Las actividades económicas que aquí se desarrollan como sectores industriales y el turismo demandan una infraestructura eléctrica sólida. Las ciudades de Barcelona, Valencia y Alicante junto con sus áreas metropolitanas, están bien conectadas a la red de

alta tensión. Finalizamos con el sur de España donde Andalucía y dentro de ella provincias como Málaga, Cádiz en la costa y Sevilla en el interior tienen una gran cantidad de municipios clasificados con zonas cercanas o medias a la red eléctrica.

La acumulación de los municipios en los rangos cercanos y medio en las zonas costeras puede explicarse por varios factores una mayor densidad de población y mayor desarrollo urbano que van a requerir una mejor infraestructura eléctrica para satisfacer la demanda de energía. Las regiones costeras son centros de actividad económica que requieren de un suministro fiable y abundante lo que ha llevado a una mayor inversión en líneas eléctricas de alta intensidad a estas zonas.

En contra partida tenemos la España vaciada donde la mayoría de los municipios aparecen con rangos lejanos a la infraestructura eléctrica de alta intensidad. Los factores que contribuyen a que la distancia en estas zonas a la red eléctrica sea más deficiente es una despoblación acusada y por lo tanto bajas densidades de población lo que significa menos demanda de energía, lo que no justifica una menor inversión en infraestructuras eléctricas de alta capacidad ya que puede ser una de las causas de la despoblación de estas zonas ya que hay muchas empresas que no se pueden instalar en estas zonas por falta de potencia eléctrica adecuada para su instalación.




Figura 70. Mapa de rangos de distancia a líneas eléctricas de alta intensidad.

4.3.5. Geoanálisis de las centrales nucleares en España.

El objetivo de este análisis es evaluar la proximidad de los municipios a las centrales nucleares en España. Este análisis ayudara a comprender los municipios que serían afectados en caso de un potencial incidente nuclear. Además se cargaran las capas de hospitales y centros de salud para poder visualizar el gran número de infraestructuras críticas de salud que serían afectadas por un fallo en los sistemas de seguridad de las centrales nucleares y sus terribles consecuencias en la población que habita esas determinadas zonas de riesgo y la que estuviera en estos centros de salud.

El primer pasó como en todos los demás geoanálisis es la importación de las bibliotecas necesarias para el análisis de las distintas capas que vamos a utilizar esto se visualiza en la (figura 71).

```

1 import geopandas as gpd
2 from scipy.spatial import KDTree
3 import numpy as np
4 import folium
5 from shapely.geometry import LineString,
  MultiLineString

```

Figura 71. Funciones para importación de librerías necesarias para el análisis.

Proseguimos con la carga de las capas necesarias para desarrollar nuestro estudio, en la (figura 72) se puede apreciar la facilidad para cargar de estas.

```

1 # Carga de las capas necesarias
2 municipios = gpd.read_file(r'C:\Users\mlain\anaconda3\
  envs\ambiente_geopandas_rasterio\Capas_IC\
  Municipios\audes2010-mun\shp\audes2010-mun.shp',
  encoding='iso-8859-1')
3 centrales_nucleares = gpd.read_file(r'C:\Users\mlain\
  anaconda3\envs\ambiente_geopandas_rasterio\Capas_IC
  \Tipos_centrales\Centrales_nucleares\
  Centrales_nucleares.geojson')

```

Figura 72. Función gpd.read_file para la carga de las capas necesarias.

La transformación del CRS al EPSG: 25830 para nuestra zona determinada de estudio en España se aprecia en la siguiente Figura X.

```

1 # Transformacion al CRS indicado para nuestra zona de
  estudios.
2 municipios = municipios.to_crs("EPSG:25830")
3 centrales_nucleares = centrales_nucleares.to_crs("EPSG
  :25830")
4 print(municipios.crs)
5 print(centrales_nucleares.crs)

```

Figura 73. Función aplicada para transformación de las coordenadas al sistema de referencia deseado.

Subsecuentemente se extraen las coordenadas x e y de los centroides de los municipios y las centrales nucleares para construir nuestro KDTree con las coordenadas de las centrales nucleares en este caso concreto. Para luego poder consultar el árbol o índice para cada municipio y así encontrar la distancia y el índice más cercano a la central nuclear. Este paso se visualiza en la (figura 74) donde se pueden observar la utilización de la librería NumPy y la librería KDTree para desarrollar esta parte con las líneas de código con las que se desarrollara esta parte del estudio.

```

1  # Extraer las coordenadas x, y de los centroides de
    los municipios y las centrales nucleares
2  municipios_coords = np.array(list(municipios['geometry
    '].centroid.apply(lambda x: (x.x, x.y))))
3  centrales_coords = np.array(list(centrales_nucleares['
    geometry'].apply(lambda x: (x.x, x.y))))
4
5  # Construir un KDTree con las coordenadas de las
    centrales nucleares
6  tree = KDTree(centrales_coords)
7
8  # Consultar el árbol para cada municipio para
    encontrar la distancia y el índice de la central má
    s cercana
9  distancias, indices = tree.query(municipios_coords)
10
11 # Añadir la información al GeoDataFrame de municipios
12 municipios['central_mas_cercana'] = [
    centrales_nucleares.iloc[idx]['etiqueta'] for idx
    in indices] # Asumiendo que las centrales tienen
    un campo 'nombre'
13 municipios['distancia_central_mas_cercana'] =
    distancias

```

Figura 74. Extraer centroides de municipios y centrales nucleares. Para luego obtener la central más cercana a cada municipio utilizando los arboles de índices KDTree.

El subsecuente proceso de código se podrá observar en la (figura 75) donde se crea un nuevo GeoDataFrame para visualizar los municipios más relevantes para luego ordenarlos por la distancia a la central más cercana de menor a mayor. Los resultados finales de este código se pueden apreciar en la figura 76.

```

1  # Crear un nuevo DataFrame para visualizar los datos
    relevantes
2  municipios_relevantes = municipios[['NOMBRE', '
    central_mas_cercana', '
    distancia_central_mas_cercana']]
3  # Ordenar los municipios por distancia a la central má
    s cercana, de menor a mayor
4  municipios_relevantes.sort_values(by='
    distancia_central_mas_cercana', ascending=True,
    inplace=True)
5
6  # Mostrar las primeras filas del DataFrame ordenado
7  print(municipios_relevantes.head(30))

```

Figura 75. Crear DataFrame para visualizar los resultados por Nombre, Central más cercana y distancias.

ID	Nombre	Central Más Cercana	Distancia
5643	Zorita de los Canes	Central Nuclear de Zorita	2293.578783
6260	Almaraz	Central Nuclear de Almaraz	2634.658547
711	Valle de Tobalina	Central Nuclear de Sta. María de Garoña	3642.021003
4101	Ascó	Central Nuclear de Ascó	4133.765118
6720	Jalance	Central Nuclear de Cofrentes	4210.620400
6191	Saucedilla	Central Nuclear de Almaraz	4721.161433
4410	Vandellós i l'Hospitalet de l'Infant	Central Nuclear de Vandellós	5080.721745
6687	Cofrentes	Central Nuclear de Cofrentes	5089.512518
4024	Vinebre	Central Nuclear de Ascó	5142.019231
6263	Romangordo	Central Nuclear de Almaraz	5441.985946
885	Partido de la Sierra en Tobalina	Central Nuclear de Sta. María de Garoña	5922.487056
5616	Yebra	Central Nuclear de Zorita	5960.445146
5526	Pastrana	Central Nuclear de Zorita	6456.088103
4902	Cifuentes	Central Nuclear de Trillo	6503.188708
3878	Flix	Central Nuclear de Ascó	6814.133534
5049	Henche	Central Nuclear de Trillo	6909.489442
5173	Trillo	Central Nuclear de Trillo	6937.093157
4047	Torre de l'Espanyol, La	Central Nuclear de Ascó	7261.651113
6226	Belvís de Monroy	Central Nuclear de Almaraz	7408.592989
5676	Albalate de Zorita	Central Nuclear de Zorita	7527.098586
730	Jurisdicción de San Zadornil	Central Nuclear de Sta. María de Garoña	7660.988317
833	Frías	Central Nuclear de Sta. María de Garoña	7719.603042
5620	Almonacid de Zorita	Central Nuclear de Zorita	7740.101376
4965	Solanillos del Extremo	Central Nuclear de Trillo	8495.395673
6743	Jarafuel	Central Nuclear de Cofrentes	8572.450627
4162	Fatarella, La	Central Nuclear de Ascó	8683.672795
5189	Mantiel	Central Nuclear de Trillo	9041.058419
6289	Valdecañas de Tajo	Central Nuclear de Almaraz	9147.920761
6293	Casas de Miravete	Central Nuclear de Almaraz	9437.578047
4582	Ametlla de Mar, L'	Central Nuclear de Vandellós	9579.575809

Figura 76. DataFrame con los resultados obtenidos de la figura 75.

Después de obtener las distancias, se crea una función para clasificar las distancias en rangos mediante unas líneas de código que se presentan en la Figura 77. Para luego aplicar la nueva función a la columna `distnaica_central_mas_cercana` permitiendo resumir grandes cantidades de datos en categorías más manejables. Esto facilita la comprensión y el análisis, ya que ahora se pueden visualizar los datos mediante distintas técnicas (mapas, gráficos de barras, tablas etc.). Los rangos permiten identificar patrones y tendencias dentro de los datos como en nuestro análisis de las centrales nucleares donde se muestran las áreas de alto riesgo de afectados por problemas en las centrales nucleares. Estos rangos además permiten comparar de manera efectiva diferentes regiones, períodos de tiempo o grupos de población.


```

1  # Clasificación basada en la distancia
2  def clasificar_proximidad(distancia):
3      if distancia < 20000: # Menos de 20 km
4          return 'Baja'
5      elif distancia < 40000: # Entre 20 km y 40 km
6          return 'Media'
7      else: # Más de 50 km
8          return 'Alta'
9
10 # Aplicar la clasificación a cada municipio
11 municipios['proximidad'] = municipios['
    distancia_central_mas_cercana'].apply(
        clasificar_proximidad)

```

Figura 77. Función para crear rangos y su aplicación a la columna distancias_central_mas_cercana.

Para finalizar el análisis de las centrales nucleares se desarrolló un mapa en Folium otra librería para crear mapas interactivos y poderlos subir a internet. Donde se muestran los distintos rangos creados anteriormente que ahora hacen el efecto de buffers, pero con toda la población que se vería afectada en cada uno de ellos por un incidente en la central nuclear.

```

1  # Inicializar el mapa centrado en España
2  mapa = folium.Map(location=[40.0, -3.5], zoom_start=6)
3
4  # Colores para cada zona
5  colores = {20: 'red', 40: 'orange', 60: 'yellow'}
6
7  # Asegurarse de que las centrales nucleares estén en
8  # EPSG:25830 para crear los buffers
9  centrales_nucleares = centrales_nucleares.to_crs(epsg=25830)
10
11 # Añadir las zonas de impacto al mapa
12 for km, color in colores.items():
13     # Crear el buffer
14     centrales_nucleares['buffer'] =
15         centrales_nucleares.geometry.buffer(km * 1000)
16     # Convertir el buffer a GeoDataFrame
17     buffer_gdf = gpd.GeoDataFrame(geometry=
18         centrales_nucleares['buffer'], crs=
19         centrales_nucleares.crs)
20     # Convertir buffer a EPSG:4326 para visualización
21     # en Folium
22     buffer_gdf = buffer_gdf.to_crs(epsg=4326)

```

Figura 78. Líneas de código para la creación del mapa en Folium.

```

1  # Añadir la zona de impacto al mapa
2  folium.GeoJson(
3      buffer_gdf.geometry,
4      style_function=lambda x, color=color: {
5          'fillColor': color, 'color': color, '
6          'fillOpacity': 0.5},
7      tooltip=f'Zona de {km} km: {
8          poblacion_afectada_por_zona[f"{km} km"]}
9          personas aproximadamente afectadas'
10     ).add_to(mapa)
11
12 # Convertir las centrales nucleares a EPSG:4326 para a
13 # ñadir marcadores en Folium
14 centrales_nucleares_4326 = centrales_nucleares.to_crs(
15     epsg=4326)
16
17 # Añadir marcadores para las centrales nucleares
18 for idx, central in centrales_nucleares_4326.iterrows
19     ():
20         folium.Marker(
21             [central.geometry.y, central.geometry.x],
22             popup=central['etiqueta'],
23             icon=folium.Icon(color='black', icon='info-
24                 sign')
25         ).add_to(mapa)
26
27 # Mostrar el mapa
28 mapa

```

Figura 79. Líneas de código para la creación del mapa en Folium.

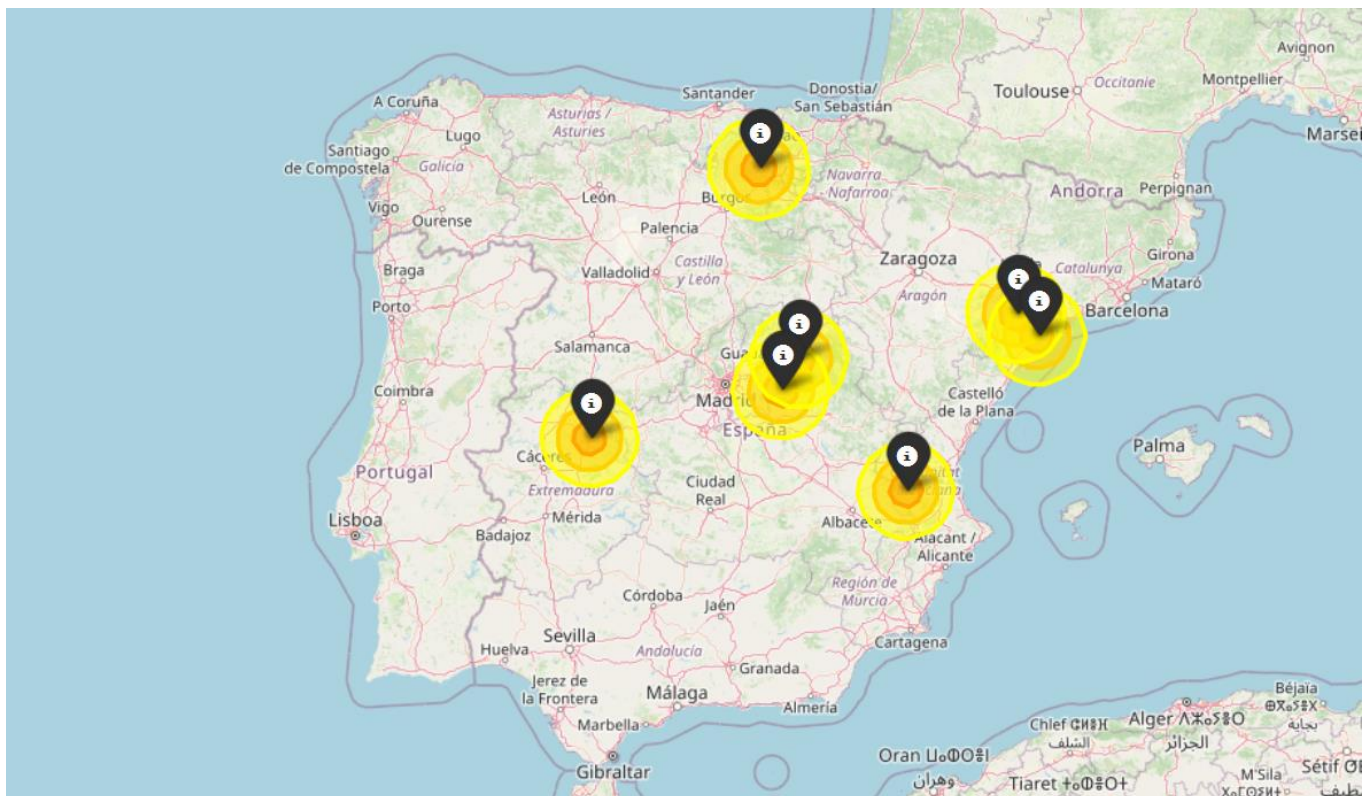


Figura 80. Mapa de los distintos buffers a las centrales nucleares de España.

Para dotar al mapa de mayor información y darle una visión aún más pesimista si cabe del accidente nuclear se añadió en la (figura 84) los hospitales, centros de salud y las autopistas que quedarían dañados e inutilizados por las terribles consecuencias de este accidente nuclear. En las siguientes (figuras 81, 82) se muestro el código y el mapa resultantes figura 83. Se añadió un mapa la figura 84 con un zoom de la zona de Madrid para ver todos los hospitales, centros de salud y autopistas que se veían afectados en cada uno de los distintos rangos.

```
1 import folium
2 import geopandas as gpd
3 from shapely.geometry import LineString,
4     MultiLineString
5
6 # Inicializar el mapa centrado en España
7 mapa = folium.Map(location=[40.0, -3.5], zoom_start=6)
8
9 # Colores para cada zona
10 colores = {20: 'red', 40: 'orange', 60: 'yellow'}
11
12 # Asegurarse de que las centrales nucleares estén en
13     EPSG:25830 para crear los buffers
14 centrales_nucleares = centrales_nucleares.to_crs(epsg
15     =25830)
16
17 # Añadir las zonas de impacto al mapa
18 for km, color in colores.items():
19     # Crear el buffer
20     centrales_nucleares['buffer'] =
21         centrales_nucleares.geometry.buffer(km * 1000)
22     # Convertir el buffer a GeoDataFrame
23     buffer_gdf = gpd.GeoDataFrame(geometry=
24         centrales_nucleares['buffer'], crs=
25         centrales_nucleares.crs)
26     # Convertir buffer a EPSG:4326 para visualización
27         en Folium
28     buffer_gdf = buffer_gdf.to_crs(epsg=4326)
29
30 # Añadir la zona de impacto al mapa
31 folium.GeoJson(
32     buffer_gdf.geometry,
33     style_function=lambda x, color=color: {
34         'fillColor': color, 'color': color, '
35         fillColor': 0.5},
36     tooltip=f'Zona de {km} km: {
37         poblacion_afectada_por_zona[f"{km} km"]}
38         personas aproximadamente afectadas'
39 ).add_to(mapa)
```

Figura 81. Código para la elaboración del mapa en Folium.

```

1  # Añadir autopistas al mapa
2  for idx, autopista in autopistas_en_zona.to_crs(
3      epsg=4326).iterrows():
4      if isinstance(autopista.geometry, LineString):
5          # Convertir la geometría en una lista de
6          # puntos para Folium
7          line_points = [(point[1], point[0]) for
8                          point in autopista.geometry.coords]
9          folium.PolyLine(
10              locations=line_points,
11              color='black',
12              weight=3,
13              popup='Autopista'
14          ).add_to(mapa)
15      elif isinstance(autopista.geometry,
16                      MultiLineString):
17          for line in autopista.geometry.geoms:
18              line_points = [(point[1], point[0])
19                              for point in line.coords]
20              folium.PolyLine(
21                  locations=line_points,
22                  color='black',
23                  weight=3,
24                  popup='Autopista'
25              ).add_to(mapa)
26      else:
27          print(f"Geometría no compatible: {
28                  autopista.geometry}")
29
30 # Mostrar el mapa
31 mapa

```

```

1  # Convertir las centrales nucleares a EPSG:4326 para a
2  # ñadir marcadores en Folium
3  centrales_nucleares_4326 = centrales_nucleares.to_crs(
4      epsg=4326)
5
6  # Añadir marcadores para las centrales nucleares
7  for idx, central in centrales_nucleares_4326.iterrows
8      ():
9      folium.Marker(
10          [central.geometry.y, central.geometry.x],
11          popup=central['etiqueta'],
12          icon=folium.Icon(color='black', icon='info-
13                          sign')
14      ).add_to(mapa)
15
16 # Cargar los datos de hospitales, centros de salud y
17 # autopistas
18 hospitales = gpd.read_file(r'C:\Users\mlain\anaconda3\
19     envs\ambiente_geopandas_rasterio\Capas_IC\
20     Hospitales\hospitales.geojson').to_crs(epsg=25830)
21 centros_salud = gpd.read_file(r'C:\Users\mlain\
22     anaconda3\envs\ambiente_geopandas_rasterio\Capas_IC\
23     Hospitales\centros_salud.geojson').to_crs(epsg
24     =25830)
25 autopistas = gpd.read_file(r'C:\Users\mlain\anaconda3\
26     envs\ambiente_geopandas_rasterio\Capas_IC\
27     Red_carreteras\Autopistas\Autopistas.geojson').
28     to_crs(epsg=25830)
29
30 # Iterar sobre cada zona de impacto para determinar la
31 # intersección con hospitales, centros de salud y
32 # autopistas
33 for km, color in colores.items():
34     buffer = centrales_nucleares.buffer(km * 1000)
35     buffer_gdf = gpd.GeoDataFrame(geometry=buffer, crs
36     =centrales_nucleares.crs)

```

Figura 82. Código para la elaboración del mapa en Folium.

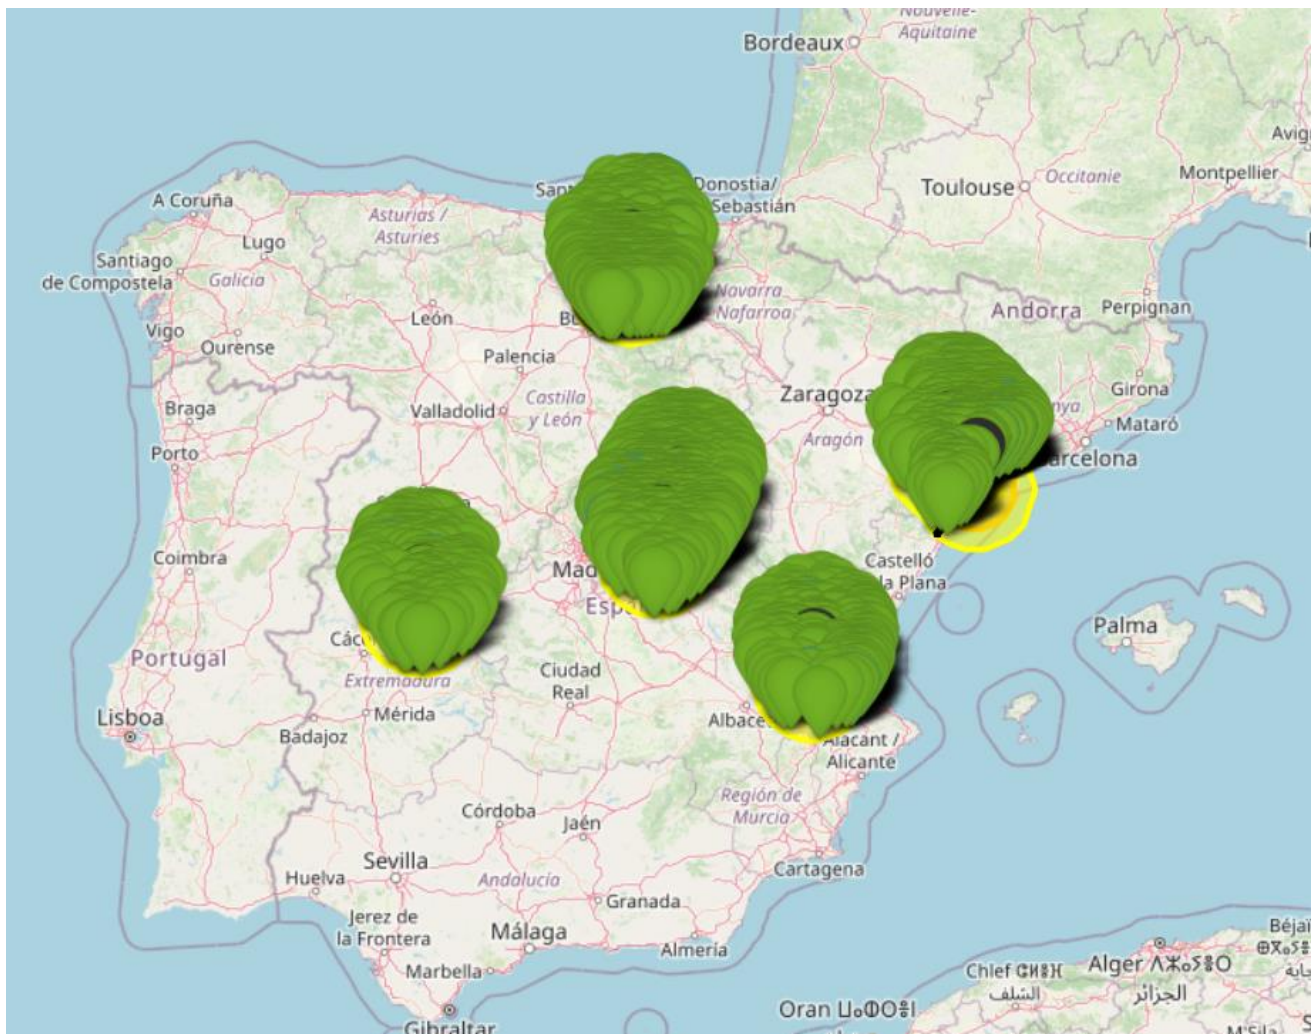


Figura 83. Mapa con los hospitales y centros de salud en cada buffer de las centrales nucleares.




Figura 84. Mapa de un zoom a la central nuclear X para ver todas las infraestructuras de salud afectadas.

4.3.6. Geoanálisis desbordamiento de los principales ríos españoles y sus afecciones a infraestructuras de la salud.

Este geoanálisis va a esclarecer como afectarían el desbordamiento de los principales ríos españoles a las infraestructuras críticas de la salud en las distintas regiones de España.

El primer pasó es la importación de todas las librerías necesarias para desarrollar este estudio.

```

1  # Las bibiotecas que se van a utilizar para este
    geoanálisis
2  import geopandas as gpd
3  import matplotlib.pyplot as plt
4  import folium

```

Figura 85. Importación de las librerías.

Cargamos las capas necesarias para el desarrollo de este geoanálisis creando una variable que las encapsule en memoria y luego utilizando gpd.read_file y la ruta de los distintos archivos para cargarlas.

```

1 # Cargamos la capas necesarias para nuestro estudio.
2 municipios = gpd.read_file(r'C:\Users\mlain\anaconda3\
  envs\ambiente_geopandas_rasterio\Capas_IC\
  Municipios\audes2010-mun\shp\audes2010-mun.shp')
3 rios = gpd.read_file(r'C:\Users\mlain\anaconda3\envs\
  ambiente_geopandas_rasterio\Capas_IC\Red_hidrográ
  fica\rios_principales.geojson')
4 red_autopistas = gpd.read_file(r'C:\Users\mlain\
  anaconda3\envs\ambiente_geopandas_rasterio\Capas_IC
  \Red_carreteras\Autopistas\Autopistas.geojson')
5 hospitales = gpd.read_file(r'C:\Users\mlain\anaconda3\
  envs\ambiente_geopandas_rasterio\Capas_IC\
  Hospitales\hospitales.geojson')

```

Figura 86. Carga de las capas.

Posteriormente se trasforman los CRS de las distintas capas al EPSG: 25830 que es el CRS que hemos utilizado para todo el desarrollo de nuestros estudios en la península ibérica.

```

1 # Transformacion del CRS y verificacion del mismo
2 municipios = municipios.to_crs("EPSG:25830")
3 rios = rios.to_crs("EPSG:25830")
4 red_autopistas = red_autopistas.to_crs("EPSG:25830")
5 hospitales = hospitales.to_crs("EPSG:25830")

```

Figura 87. Transformación de las coordenadas.

Cuando ya se han homogeneizado todos los CRS de las distintas capas, se crean los buffers alrededor de los ríos definiendo primero el tamaño del buffer que se le va a aplicar a cada gran río de España.

```

1 # Crear buffers alrededor de los ríos.
2 # Definir el tamaño del buffer, por ejemplo, 1000
  metros
3 buffer_size = 1000 # metros
4 rios_buffered = rios.buffer(buffer_size)

```

Figura 88. Crear la variable del tamaño del buffer y se le aplica a la variable ríos.

La siguiente línea de código que se podrá visualizar en la (figura 89) es una comprobación de tipo de datos y, si es necesario, convierte un objeto Geoseries en un GeoDataFrame. Con esta línea de código `if isinstance(rios_buffered, gpd.GeoSeries)` verificamos si el objeto `rios_buffer` es una Geoserie de Pandas. Al verificar que es así, la convertimos a un GeodataFrame `gpd.GeoDataFrame(geometry=rios_buffered)` debido a que es más versátil y puede contener múltiples columnas adicionales de datos no solo la geometría además te permite realizar operaciones que una Geoseries no puede realizar.


```

1 # Transformación Geoserie a GeoDataFrame
2 if isinstance(rios_buffered, gpd.GeoSeries):
3     rios_buffered = gpd.GeoDataFrame(geometry=
        rios_buffered)

```

Figura 89. Transformación GeoSerie a GeoDataFrame.

La intersección de los municipios con las áreas de desbordamiento (figura90) llamadas en nuestro caso ríos_buffered es el subsecuente paso para obtener el objetivo de este microestudio.

```

1 # Intersección de municipios con áreas de
    desbordamiento
2 municipios_afectados = gpd.overlay(municipios,
    rios_buffered, how='intersection')

```

Figura 90. Intersección de municipios con ríos_buffer mediante función gpd.overlay.

Después de obtener esta intersección se presentó una pregunta que era ¿Cuántos municipios y habitantes habrían sido afectados por dicho desbordamiento? La cual fue respondida con unas simples líneas de código que se pueden observar en la figura 91.

```

1 # Contar municipios afectados y sumar población
2 num_municipios_afectados = municipios_afectados.shape
    [0]
3 poblacion_total_afectada = municipios_afectados['HBT'
    ].sum() # Asumiendo que hay una columna 'poblacion'
4
5 print(f"Número de municipios afectados: {
    num_municipios_afectados}")
6 print(f"Población total afectada: {
    poblacion_total_afectada}")

```

Figura 91. Contabilizar municipios y población afectada.

```

Número de municipios afectados: 651
Población total afectada: 6445486

```

Figura 92. Resultados de la contabilización

El siguiente paso es incluir los hospitales y la red de autopistas al análisis por lo tanto nos aseguramos de que todas las capas estén en un mismo sistema de coordenadas para que se pueda realizar la intersección de ambos con ríos_bufferes para obtener todos aquellos hospitales y trozos de autopistas

que se verían afectados por la inundación. Para luego mostrar los nombres de estas infraestructuras críticas de salud y trozos de autopistas afectadas por la inundación.

```

1  # Asegurándonos de que todo esté en el mismo CRS (por
    ejemplo, EPSG:25830)
2  rios_buffered = rios_buffered.to_crs(epsg=25830)
3  red_autopistas = red_autopistas.to_crs(epsg=25830)
4  hospitales = hospitales.to_crs(epsg=25830)
5
6  # Ahora que todo está en el mismo CRS, podemos
    realizar la operación de overlay
7  autopistas_afectadas = gpd.overlay(red_autopistas,
    rios_buffered, how='intersection')
8  hospitales_afectados = gpd.overlay(hospitales,
    rios_buffered, how='intersection')
9
10 # Listar los hospitales afectados
11 print("Hospitales afectados:")
12 print(hospitales_afectados[['etiqueta']])
13
14 # Listar las autopistas afectadas
15 print("\nAutopistas afectadas:")
16 print(autopistas_afectadas[['nombre']])

```

Figura 93. Carga de hospitales y autopistas en sus sistemas de coordenadas óptimas. Realización de las operaciones de overlay con las infraestructuras cargadas.

```

Hospitales afectados:
                                etiqueta
0      Hospital General de La Rioja
1      Hospital San Juan de Tudela
2      Hospital Virgen de la Cinta
3      Hospital Comarcal De Mora d'Ebre
4      Hospital Campoo
5      Complejo Asistencial Soria
6      Hospital Provincial Zamora
7      Hospital de Recoletas
8      Complejo Hospitalario Alameda
9      Hospital Virgen de la Luz
10     Hospital de Santiago Apóstol
11     Hospital San Carlos
12     Hospital General Reina Sofía
13     Hospital Alto Guadalquivir
14     Hospital San Andrés
15     Hospital Cruz Roja
16     Hospital de San Sebastián
17 Hospital Universitario Provincial San Sebastián
18     Hospital de Mérida
19     Hospital Provincial de la Misericordia
20     Hospital Virgen de la Salud
21     Hospital Nuncio Nuevo

```

Figura 94. Hospitales afectados por los desbordamientos.

Autopistas afectadas:

	nombre
0	R-4
1	R-4
2	R-4
3	R-4
4	R-4
..	...
153	AP-7N
154	AP-7N
155	AP-7N
156	AP-7N
157	AP-7N

Figura 95. Tramos de autopistas afectados por desbordamientos de los principales ríos.

Para finalizar este geoanálisis solo nos falta la representación de los datos en mapas para una mejor visualización y entendimiento de la situación hipotética en la que estamos trabajando. Para ello se quiso esta vez utilizar la biblioteca de Folium para la representación de los datos de forma dinámica. Para lo cual se deben de transformar las coordenadas a otro sistema de referencia que es el que utiliza Folium el EPSG: 4326.

```
1 # Transformacion al CRS que folium necesita para su  
2 posterior representacion.  
2 rios_buffered = rios_buffered.to_crs(epsg=4326)  
3 municipios_afectados = municipios_afectados.to_crs(  
    epsg=4326)  
4 autopistas_afectadas = autopistas_afectadas.to_crs(  
    epsg=4326)  
5 hospitales_afectados = hospitales_afectados.to_crs(  
    epsg=4326)
```

Figura 96. Transformación de coordenadas para la visualización en Folium.

```

1  # Creacion del mapa en folium
2  mapa = folium.Map(location=[40.0, -3.5], zoom_start=6)
3
4  # Añadir los ríos al mapa
5  for idx, rio in rios.iterrows():
6      folium.GeoJson(rio['geometry'], name='Ríos').
7          add_to(mapa)
8
9  # Añadir áreas de desbordamiento (buffers) al mapa
10 for idx, area in rios_buffered.iterrows():
11     folium.GeoJson(area['geometry'], name='Áreas de
12         Desbordamiento', style_function=lambda x: {'
13             color': 'blue', 'fillColor': 'blue', '
14             fillOpacity': 0.5}).add_to(mapa)
15
16 # Añadir autopistas afectadas al mapa con tooltip
17 for idx, autopista in autopistas_afectadas.iterrows():
18     tooltip = folium.Tooltip(autopista['nombre']) #
19         Usando 'nombre' para la tooltip
20     folium.GeoJson(autopista['geometry'], name='
21         Autopistas Afectadas', style_function=lambda x:
22         {'color': 'red'}, tooltip=tooltip).add_to(mapa
23         )
24
25 # Añadir hospitales afectados al mapa con tooltip
26 for idx, hospital in hospitales_afectados.iterrows():
27     tooltip = folium.Tooltip(hospital['etiqueta'])
28     folium.GeoJson(hospital['geometry'], name='
29         Hospitales Afectados', style_function=lambda x:
30         {'color': 'green'}, tooltip=tooltip).add_to(
31         mapa)
32
33 folium.LayerControl().add_to(mapa)
34 mapa

```

Figura 97. Código para la elaboración del mapa en Folium.



Figura 98. Mapa de hospitales y tramos de autopistas afectados por desbordamientos de 1km.

Posteriormente se presenta en las (figuras 99, 100, 101, 102,103) el código y sus respectivos mapas de cómo se crearon las distintas hipótesis de desbordamientos a 500, 1000,1500 metros y sus afecciones derivadas a los hospitales y autovías con la biblioteca de Folium.


```

1 import folium
2 from IPython.display import display
3
4 # Transformar los ríos al CRS de Folium antes de
   iniciar el bucle
5 rios_4326 = rios.to_crs(epsg=4326)
6
7 for buffer_size in buffer_sizes:
8     # Crear el buffer para simular el área inundada (
       en EPSG:25830)
9     rios_buffered = rios.buffer(buffer_size)
10
11     # Convertir el GeoSeries resultante a GeoDataFrame
12     rios_buffered_gdf = gpd.GeoDataFrame(geometry=
       rios_buffered, crs=rios.crs)
13
14     # Calcular las intersecciones con hospitales y
       autopistas para este escenario
15     hospitales_afectados = gpd.overlay(hospitales,
       rios_buffered_gdf, how='intersection')
16     autopistas_afectadas = gpd.overlay(red_autopistas,
       rios_buffered_gdf, how='intersection')
17
18     # Iniciar el mapa
19     mapa = folium.Map(location=[40.0, -3.5],
       zoom_start=6)
20
21     # Añadir los ríos al mapa
22     for idx, rio in rios_4326.iterrows():
23         folium.GeoJson(rio['geometry'], name='Ríos').
           add_to(mapa)
24
25     # Añadir el área de desbordamiento al mapa (
       necesita ser transformada a EPSG:4326 para
       visualización)
26     folium.GeoJson(rios_buffered_gdf.to_crs(epsg=4326)
       , name=f'Áreas de Desbordamiento {buffer_size}m'
       , style_function=lambda x: {'color': 'blue', '
       fillColor': 'blue', 'fillOpacity': 0.5}).add_to
       (mapa)

```

Figura 99. Código para la creación de los mapas en Folium.

```

1
2     # Añadir autopistas afectadas al mapa con tooltip
3     # Asegúrate de que autopistas_afectadas esté en
       EPSG:4326 para visualización
4     for idx, autopista in autopistas_afectadas.to_crs(
       epsg=4326).iterrows():
5         tooltip = folium.Tooltip(autopista['nombre'])
6         folium.GeoJson(autopista['geometry'], name=f'
           Autopistas Afectadas {buffer_size}m',
           style_function=lambda x: {'color': 'red'},
           tooltip=tooltip).add_to(mapa)
7
8     # Añadir hospitales afectados al mapa con tooltip
9     # Asegúrate de que hospitales_afectados esté en
       EPSG:4326 para visualización
10    for idx, hospital in hospitales_afectados.to_crs(
       epsg=4326).iterrows():
11        tooltip = folium.Tooltip(hospital['etiqueta'])
12        folium.GeoJson(hospital['geometry'], name=f'
           Hospitales Afectados {buffer_size}m',
           style_function=lambda x: {'color': 'green'
           }, tooltip=tooltip).add_to(mapa)
13
14    # Añadir control de capas
15    folium.LayerControl().add_to(mapa)
16
17    # Mostrar el mapa
18    display(mapa)

```

Figura 100. Código para la creación de los mapas en Folium.

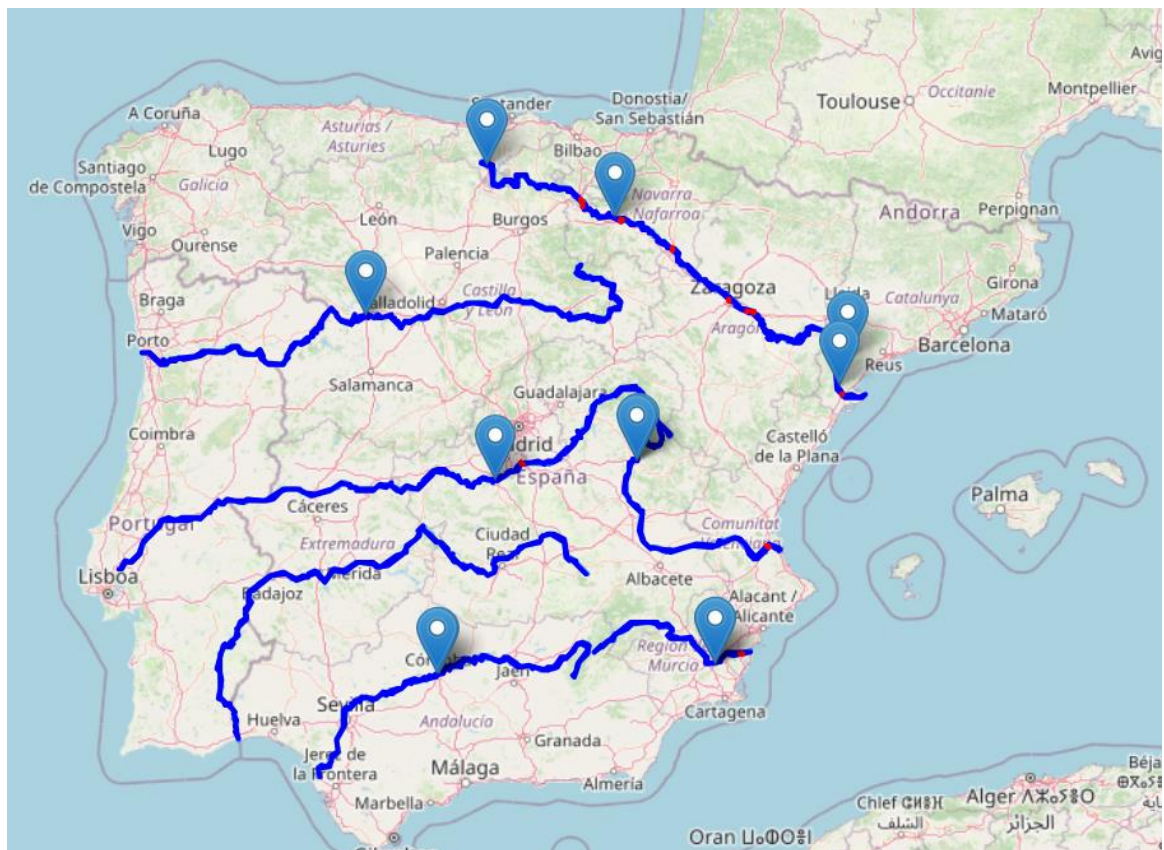


Figura 101. Mapa de las afecciones por buffer de 500 m a los ríos principales.

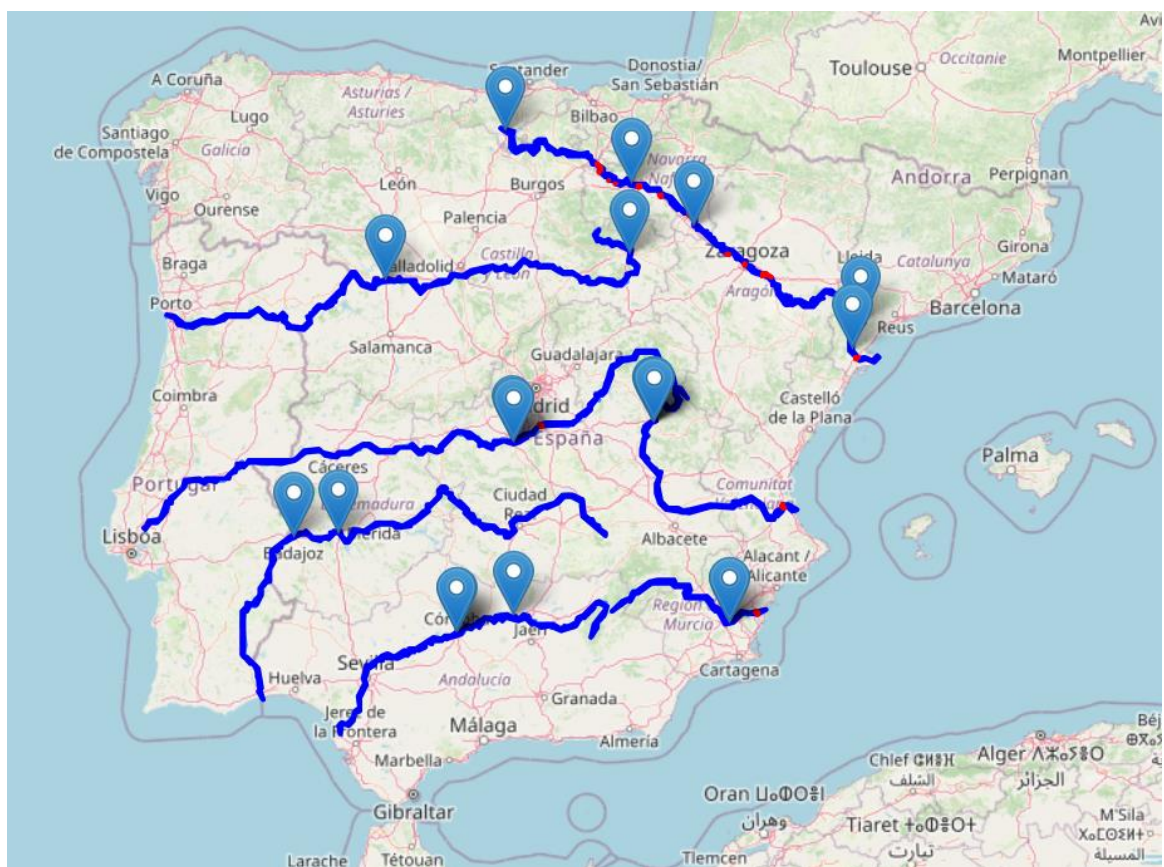


Figura 102. Mapa de las afecciones por buffer de 1000 m a los ríos principales.

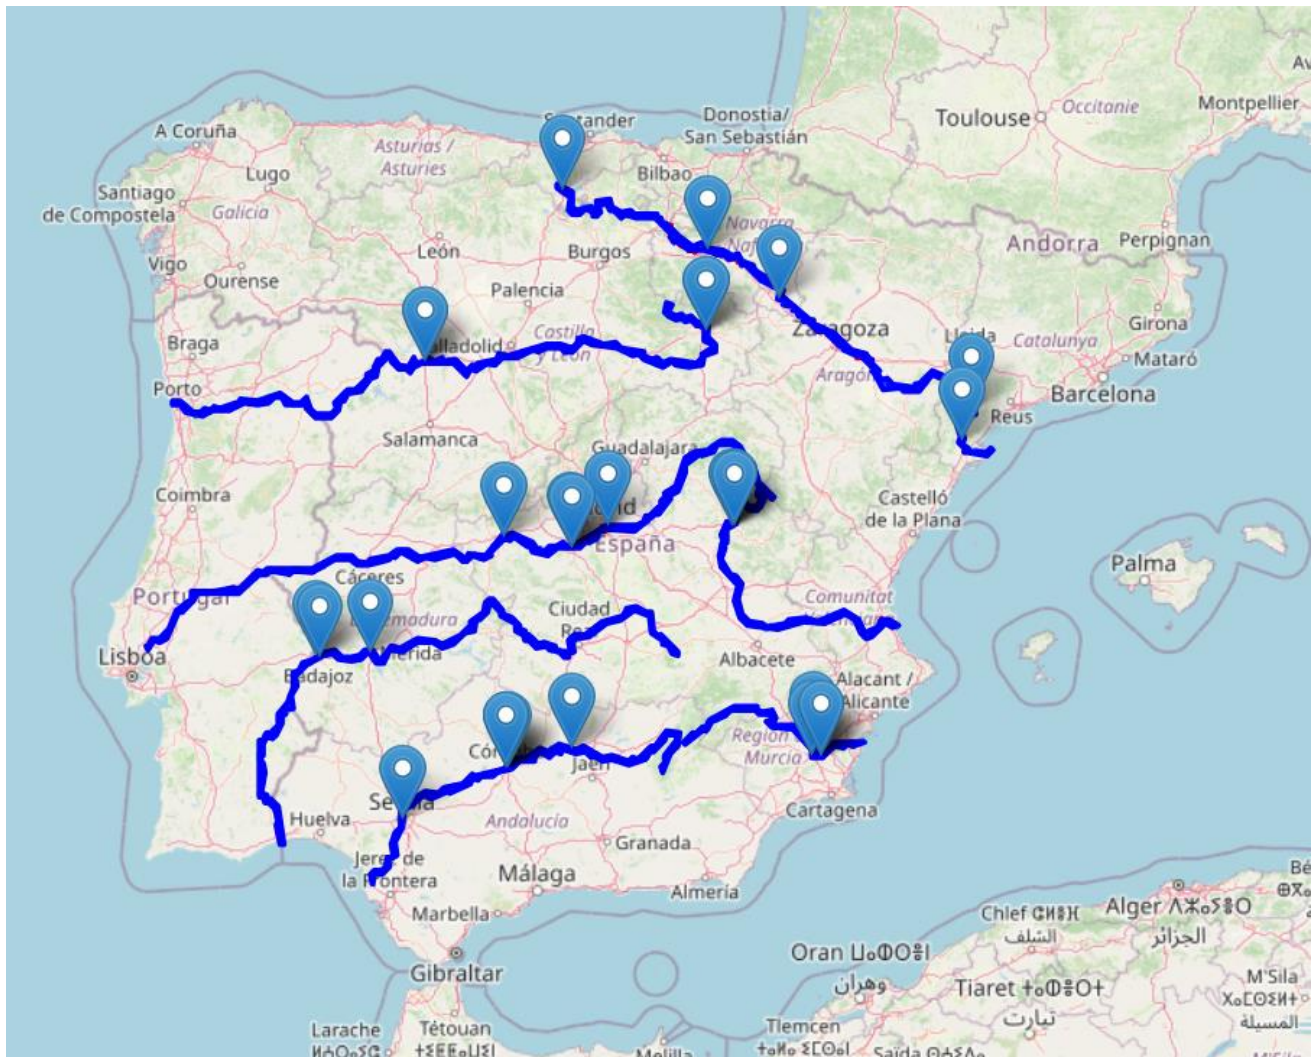


Figura 103. Mapa de las afecciones por buffer de 1500 m a los ríos principales.

4.3.7. Geoanálisis de la red de autopistas y los municipios.

Este análisis se encarga de obtener todos aquellos municipios que presentan una mayor vulnerabilidad al encontrarse alejados de las principales autopistas de España. Las autopistas proporcionan una serie de beneficios cruciales como sería el acceso a mercados y centros industriales, permitiendo un transporte más eficiente de bienes y materias primas. Esto es un aspecto esencial para la competitividad de las empresas locales y la atracción de inversiones. Además España es un destino turístico de los más importantes del mundo y las autopistas facilitan el acceso a los destinos turísticos contribuyendo al crecimiento del sector. Además las autopistas promueven un desarrollo más equilibrado al conectar zonas urbanas con zonas rurales, esto podría ayudar a reducir las disparidades económicas entre diferentes partes del país.

Comenzamos nuestro estudio de la red de autopistas y sus relaciones con los municipios importando las librerías correspondientes para este análisis, las cuales se observan en la (figura 104).

```

1 import geopandas as gpd
2 from shapely.ops import triangulate
3 from shapely.geometry import Polygon
4 import matplotlib.pyplot as plt
5 import random
6 import folium
7 from shapely.ops import unary_union
8 from scipy.spatial import cKDTree
9 import numpy as np
10 from shapely.geometry import MultiLineString
11 from shapely.geometry import box
12 from geopandas.tools import sjoin

```

Figura 104. Importación de librerías.

Seguimos con la carga de las capas para el desarrollo de este análisis, en concreto como se ha estado realizando en la totalidad de los análisis y su transformación al crs óptimo para nuestra zona de estudio que es el EPSG: 25830.

```

1 # Carga la red de autopistas desde un archivo GeoJSON.
2 red_autopistas = gpd.read_file(r'C:\Users\mlain\
    anaconda3\envs\ambiente_geopandas_rasterio\Capas_IC
    \Red_carreteras\Autopistas\Autopistas.geojson')
3 # Carga de la capa de municipios desde un archivo
    shapefile.
4 municipios = gpd.read_file(r'C:\Users\mlain\anaconda3\
    envs\ambiente_geopandas_rasterio\Capas_IC\
    Municipios\audes2010-mun\shp\audes2010-mun.shp',
    encoding='iso-8859-1')

```

```

1 # Transformación de el CRS
2 municipios = municipios.to_crs("EPSG:25830")
3 red_autopistas = red_autopistas.to_crs("EPSG:25830")

```

Figura 105. Carga de datos y transformación al crs óptimo para nuestro análisis.

Para saber si las geometrías son válidas para nuestro análisis se verifico primero las geometrías y luego se repararon todas aquellas que podrían ser inválidas con un buffer (0) que es un proceso que se utiliza mucho para corrección de geometrías dentro del ambiente de Jupyter Notebook.

```

1 # Verificar geometrías inválidas
2 municipios[municipios.geometry.is_valid == False]
3
4 # Reparar geometrías inválidas (si las hay)
5 municipios.geometry = municipios.geometry.buffer(0)

```

Figura 106. Verificación de geometrías inválidas y su posterior transformación.

Subsecuentemente de reparar las geometrías inválidas convertimos estas geometrías en punto, se usara el punto más representativo de cada geometría y se creara el árbol KDtree para una mejor indexación y búsqueda. Para luego crear una lista de distancias_minimas e iterar dentro de municipios y luego buscar en el árbol las distancias de una forma más eficiente.

```
1 # Convertir las geometrías de las autopistas en puntos
  (si aún no lo están)
2 # Aquí usamos el punto representativo de cada geometría
  a
3 puntos_autopistas = np.array(list(red_autopistas.
  geometry.apply(lambda geom: geom.
  representative_point().coords[0])))
4
5 # Crear el árbol k-d con los puntos 2D
6 tree = cKDTree(puntos_autopistas)
```

```
1 # Creación de lista vacía para distancias e iteración
2 distancias_minimas = []
3 for _, municipio in municipios.iterrows():
4     # Verificar si el centroide es válido antes de
      usarlo
5     if municipio.geometry.is_empty or municipio.
      geometry.centroid.is_empty:
6         dist = np.nan # Usar NaN para municipios con
          geometrías inválidas
7     else:
8         dist, _ = tree.query(municipio.geometry.
          centroid.coords[0])
9         dist /= 1000 # Convertir de metros a kiló
          metros
10    distancias_minimas.append(dist)
11
12 municipios['distancia_minima_km'] = distancias_minimas
    # Usar un nuevo nombre de columna para claridad
```

Figura 107. Convertir geometrías a punto, creación del árbol KDTree e iterar sobre ellas para obtener las distancias mínimas en kilómetros del municipio a la autopista más cercana.

Posteriormente se visualizaron las distancias mínimas en kilómetros desde cada municipio a la autopista más cercana. Para luego ordenar los municipios por la distancia mínima de menor a mayor.

```
1 # Ver las primeras distancias mínimas en kilómetros
2 print(municipios[['NOMBRE', 'distancia_minima_km']].
  head(20))
```

Figura 108. Visualizar distancias mínimas en kilómetros de cada municipio a la autopista más cercana.

	NOMBRE	distancia_minima_km
0	Mañón	38.471671
1	Cariño	33.034099
2	Vicedo, O	44.545191
3	Ortigueira	31.781249
4	Cedeira	23.365279
5	Xove	55.759703
6	Cervo	61.038356
7	Viveiro	48.598432
8	Valdoviño	11.975471
9	Burela	66.558774
10	Cerdido	20.463232
11	Foz	67.621039
12	Ourot	42.366923
13	Gozón	54.574235
14	Moeche	16.445455
15	Narón	4.064335
16	Ferrol	5.691101
17	San Sadurniño	9.679366
18	Valadouro, O	54.911317
19	Somozas, As	19.526475

Figura 108. Resultados obtenidos de las distancias mínimas de los municipios a la autopista más cerca.

```

1  # Ordenar los municipios por distancia mínima en kiló
    metros de menor a mayor
2  municipios_ordenados = municipios.sort_values(by='
    distancia_minima_km')
3
4  # Ver las primeras 20 distancias mínimas en kilómetros
    junto con los nombres de los municipios
5  primeras_distancias_ordenadas = municipios_ordenados[[
    'NOMBRE', 'distancia_minima_km']].head(20)
6  print(primeras_distancias_ordenadas)
7
8  # Obtener un resumen estadístico de las distancias en
    kilómetros
9  resumen_estadistico = municipios['distancia_minima_km',
    ].describe()
10 print(resumen_estadistico)

```

Figura 109. Código para ordenar los municipios de menor a mayor y visualizar resultados por pantalla.

	NOMBRE	distancia_minima_km
3471	Montgat	0.031860
3138	Roca del Valls, La	0.057318
8069	Torremolinos	0.068117
6070	Villaseca de la Sagra	0.072638
4265	Cambrils	0.083066
5828	Carranque	0.088661
3135	Sant Pol de Mar	0.098024
3133	Canet de Mar	0.104937
399	Bergara	0.112595
3248	Mollet del Valls	0.119007
2476	Sant Juli de Vilatorra	0.140606
6962	Verger, el	0.140767
1594	Marcilla	0.143135
2178	Sarri de Ter	0.154501
3273	Montcada i Reixac	0.158484
43	Fene	0.166694
5904	Seseña	0.170329
3225	Mataró	0.176997
3442	Soses	0.192410
3038	Sant Vicen de Castellet	0.200110
count	8200.000000	
mean	66.316174	
std	138.073824	
min	0.031860	
25%	15.965115	
50%	44.692951	
75%	82.365051	
max	1499.105621	

Figura 110. Resultados obtenidos del código de la figura 109.

Para clasificar la vulnerabilidad de los municipios, se definió una función para clasificar estos municipios en un determinado rango como se observa en la figura 111.

```

1 def clasificar_vulnerabilidad(distancia):
2     if distancia < 25: # Menos de 25 km
3         return 'Baja'
4     elif distancia < 50: # Entre 25 km y 50 km
5         return 'Media'
6     else:
7         return 'Alta'
8
9 municipios['vulnerabilidad'] = municipios['
    distancia_minima_km'].apply(
        clasificar_vulnerabilidad)

```

Figura 111. Función para clasificar las distancias.

Para plasmar estos resultados se crearon dos mapas uno con la librería Matplotlib y otro con la librería de Folium los cuales podréis apreciar en las (figuras 112, 113) para saber cómo se distribuye geográficamente la vulnerabilidad de estos municipios.




Figura 109. Mapa de la distribución de la vulnerabilidad dependiendo de la distancia a las autopistas más cercanas con la librería Matplotlib.

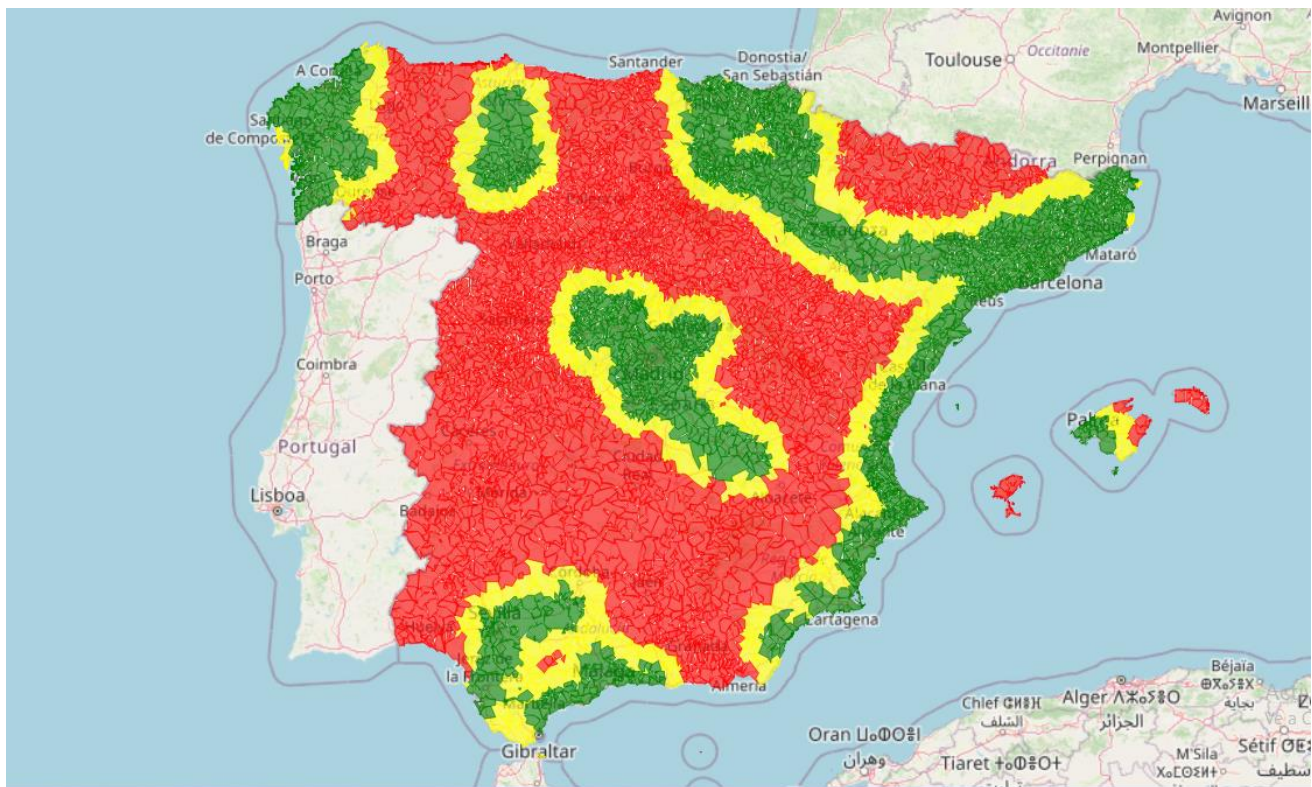


Figura 110. Mapa de la distribución de la vulnerabilidad dependiendo de la distancia a las autopistas más cercanas con la librería interactiva Folium.

4.3. Limpieza y transformación de datos automatizada en Python.

En el contexto de la geografía, la teledetección y el data science, la limpieza de los datos son etapas cruciales para garantizar la precisión y la utilidad de los análisis geoespaciales. La limpieza de datos es fundamental en cualquier proyecto a gran escala y con cantidades masivas de datos, ya que mejora la calidad y la precisión de los análisis posteriores (Kandel et al., 2011)

El flujo de trabajo que hemos seguido en la parte de limpieza y transformación se puede visualizar rápidamente en el siguiente organigrama de la (figura 111).

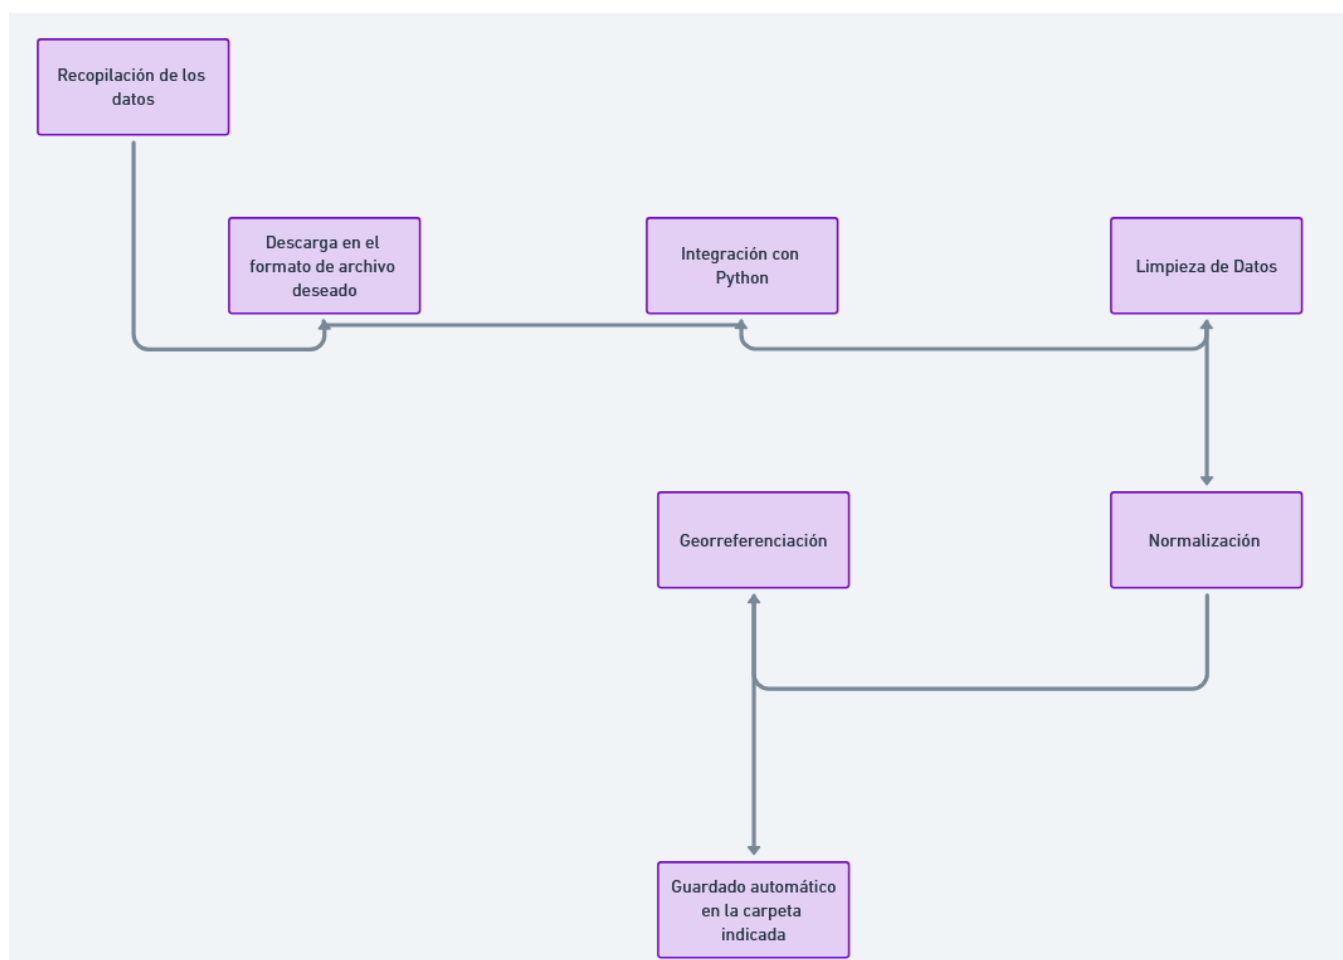


Figura 111. Organigrama del flujo de trabajo en la limpieza y transformación de los datos.

La recopilación de datos geoespaciales para este estudio se realizó a través de la plataforma SIGNA del Instituto Geográfico Nacional (IGN) como se ha comentado en el anterior punto, dicha plataforma proporciona un acceso integral a una amplia variedad de capas en distintos formatos de datos georreferenciados de España. Se eligió descargar todos los archivos en formato GeoJSON por sus ventajas en términos de interoperabilidad y facilidad de uso en análisis geoespaciales, especialmente en entornos de programación como Python.

El script que se elaboró para la automatización de la limpieza y transformación de los datos fue el siguiente:

El primer paso fue la importación de las librerías necesarias para poder trabajar con los datos y poder transformarlos.

```

1 import geopandas as gpd
2 import os
3 from shapely.geometry import Point, LineString,
  Polygon, MultiPolygon

```

Figura 112. Importación de las librerías.

Posteriormente se crea una variable en Python que contendrá la ruta donde se aloja el archivo correspondiente que es lo único que cambiara con cada uno de los archivos para su limpieza.

```
1 # Asegúrate de que la ruta esté correctamente asignada
  a la variable
2 aeropuertos = r'C:\Capas_IC\Transportes\Aeropuertos\
  Aeropuertos.geojson'
```

Figura 113. Creación variable que contendrá la ruta de del archivo.

Ahora se crea una función que llama limpiar_geodataframe la cual va a contener la variable de ruta y el crs_final al que queremos que se encuentren todas nuestras capas después de estos procesos.

Esta función lleva una primera parte que nos avisa si no encuentra la ruta para que nos demos cuenta donde está fallando la función. La siguiente parte de la función carga el archivo GoeJSON hace una pequeña inspección inicial para saber que contiene el archivo. Seguido a ello empezamos con la limpieza de los duplicados y valores nulos para finalmente terminar con la georreferenciación del archivo al crs_final que le hemos indicado en los parámetros de la función. Todo esto está dentro de un try except que se utiliza para saber en qué parte de todas estas acciones ha fallado el proceso.

```
1 def limpiar_geodataframe(ruta, crs_final='EPSG:25830')
  :
2     if not os.path.exists(ruta):
3         print(f"Ruta no encontrada: {ruta}")
4         return None
5
6     try:
7         # Carga del GeoDataFrame
8         gdf = gpd.read_file(ruta)
9         print("Archivo cargado correctamente.")
10
11        # Inspección inicial
12        print("Inspección inicial:")
13        print(gdf.head())
14        print(gdf.info())
15
16        # Limpieza de duplicados y valores nulos
17        gdf_clean = gdf.drop_duplicates().dropna()
18        print(f"Registros después de limpiar: {len(
19            gdf_clean)}")
20
21        # Ajuste del CRS
22        if gdf_clean.crs is not None and gdf_clean.crs
23            .to_string() != crs_final:
24            gdf_clean = gdf_clean.to_crs(crs_final)
25            print(f"CRS ajustado a {crs_final}.")
26        elif gdf_clean.crs is None:
27            gdf_clean.set_crs(crs_final, inplace=True)
28            print(f"CRS establecido a {crs_final} ya
29                que no estaba definido.")
30
31        return gdf_clean
32
33    except Exception as e:
34        print(f"Error al procesar el archivo {ruta}: {
35            e}")
36        return None
```

Figura 113. Creación de función para limpiar los GeoDataFrames

El siguiente paso es llamar a la función `limpiar_geodataframe` anteriormente creada para activarla y limpiar nuestro archivo GeoJSON y que nos muestre que contiene dicho archivo y las columnas que presenta además de la columna non-null que es donde veremos que se han eliminado duplicados y que no contiene ningún valor nulo.

```
1 # Llamar a la función para limpiar el GeoDataFrame
2 gdf_aeropuertos = limpiar_geodataframe(aeropuertos)
3
4 if gdf_aeropuertos is not None:
5     print("Limpieza completada. Aquí están los
6         primeros registros del GeoDataFrame limpio:")
7     print(gdf_aeropuertos.head())
```

Figura 114. Se llama a la función para que limpie los datos.

Se prosigue con la explicación del script para automatizar la limpieza de datos. En el siguiente recuadro se puede observar que lo que queremos realizar es homogeneizar todos los campos de nuestro GeoDataFrame para así posteriormente poder juntar todos los elementos de nuestras capas en un solo GeoDataFrame que contenga todas las infraestructuras con las que posteriormente realizaremos las combinaciones de dichas infraestructuras para crear los escenarios. Por lo tanto como podemos visualizar en la (figura 115) se cambian de nombre aquellas columnas que se llamen `objectid` por `id` y se le quita columnas sobrantes.

```
1 # Cambiar el nombre de la columna 'objectid' a 'id' en
   gdf_eolicas
2 gdf_aeropuertos = gdf_aeropuertos.rename(columns={'
   objectid': 'id'})
3
4 # Quitar columnas sobrantes
5 gdf_aeropuertos = gdf_aeropuertos.drop(columns=['
   desc_tipo_0503', 'etiqueta'])
6
7 # Mostrar las primeras filas para verificar el nuevo
   orden de columnas
8 print(gdf_aeropuertos.head(40)) # Muestra las
   primeras 5 filas por defecto
9 gdf_aeropuertos
```

Figura 115. Cambiar nombre de las columnas `objectid` por `id` y quitar columnas que no se necesitan para nuestro estudio.

En la siguiente parte de nuestro código se van a eliminar todas aquellas filas dentro de la columna `geometry` que son `none` esto quiere decir que no hay dato porque estos `nones` pueden causar problemas a la hora de procesar los datos.

```

1 # Eliminar filas donde las columnas 'geometry' son
   None
2 gdf_aeropuertos = gdf_aeropuertos.dropna(subset=['
   geometry'])
3
4 # Verificación: imprimir el número de registros despué
   s de la limpieza y mostrar las primeras filas
5 print(f"Registros después de la limpieza: {len(
   gdf_aeropuertos)}")
6 gdf_aeropuertos

```

Figura 116. Eliminar filas donde la columna geometry sea None.

Para ir finalizando con este script de automatización de la limpieza de datos vamos a pasar con uno de las funciones de mayor importancia dentro de este script. La función convertir_geometrías que presenta dos parámetros dentro de ella el gdf y el buffer_size=0.01 es un paso muy utilizado en programación cuando trabajamos con elementos geográficos que se trasforman a un modelo de datos en este caso vectorial se hace un pequeño buffer para tras formarlas todas a polígonos. Nos aseguramos de que no hay geometrías nulas o vacías antes de trasformar, lo siguiente será aplicar un pequeño buffer a todas las geometrías para convertirlas a polígonos.

```

1 def convertir_geometria(gdf, buffer_size=0.0001):
2     # Asegurar que no hay geometrías nulas o vacías
   antes de transformar
3     gdf = gdf[gdf['geometry'].notna() & ~gdf['geometry
   '].is_empty]
4
5     # Aplicar un pequeño buffer a todas las geometrías
   para convertirlas en polígonos
6     gdf['geometry'] = gdf['geometry'].apply(lambda
   geom: geom.buffer(buffer_size))
7
8     # Si hay geometrías múltiples después del buffer,
   usar unary_union para combinarlas
9     # Agrupar por todas las columnas menos 'geometry'
   para mantener las propiedades únicas
10    if any(gdf.explode(index_parts=False)['geometry'].
   type.str.startswith('Multi')):
11        gdf = gdf.dissolve(by=gdf.columns.drop('
   geometry').tolist())
12
13    return gdf
14
15 # Suponiendo que gdf_rios es tu GeoDataFrame de ríos
gdf_aeropuertos = convertir_geometria(gdf_aeropuertos)
16
17 # Verificación
gdf_aeropuertos
18

```

Figura 117. Homogeneizar todas las geometrías a tipo polígono.

Para finalizar la explicación de este script de automatización se comprueba que el CRS es el indicado para nuestras preferencias que en este caso el EPSG: 25830 y de define la ruta de la carpeta a la cual queremos guardar todas nuestras capas limpiar para el posterior tratamiento y análisis.

```

1 print("CRS actual de gdf_aeropuertos:",
      gdf_aeropuertos.crs)
2 # Definir la ruta de la carpeta donde quieres guardar
  el archivo
3 folder_path = r'C:\Users\mlain\proyecto_practiva_tfm\
  gdf_infraestructuras_limpios\
  GeoDataFrames_limpios_tipo_poligono'
4 file_name = 'gdf_aeropuertos.geojson'
5 file_path = os.path.join(folder_path, file_name)
6
7 # Guardar el GeoDataFrame en formato GeoJSON
8 gdf_aeropuertos.to_file(file_path, driver='GeoJSON')
9
10 print(f'GeoDataFrame guardado correctamente en {
      file_path}')

```

Figura 118. Comprobación automatizada del crs indicado para nuestro proyecto y guardado automático en carpeta deseada.

Con herramientas como GeoPandas en Python, podemos automatizar la limpieza, la normalización y georreferenciación de los datos como se ha podido observar en el desarrollo de nuestro script de automatización de limpieza de datos, tareas que serían más laboriosas y propensas a errores en sistemas SIG tradicionales. Por otro lado la capacidad de Jupyter notebooks para documentar el proceso de análisis paso a paso, combinar el código, visualizaciones y narrativas, contribuye a la transparencia y reproducibilidad de la investigación. Esto es esencial para validar los resultados y facilitar su revisión por parte de otros investigadores.

4.4. Automatizando la creación de los buffers con Python.

En el análisis geoespacial, la creación de buffers es una técnica comúnmente utilizada para definir zonas de influencia alrededor de objetos geográficos. En este proyecto, se encontró otro desafío significativo, un problema de memoria al intentar crear buffers para grandes volúmenes de datos en un entorno Jupyter Notebook mientras se realizaban otras tareas simultáneamente como intersecciones, disolves, las propias combinaciones para obtener nuestros escenarios regionales. Se optó por abordar este desafío haciendo uso del scripting para el que fue creado Python, la automatización de procesos mediante scripts que pueden ser reutilizados para diferentes conjuntos de datos.

El script utilizado para solventar desafío fue el siguiente, como siempre lo primero de todo es pensar en que librerías vamos a utilizar para poder importarlas a nuestro proyecto.

```

1 import geopandas as gpd
2 import os

```

Figura 119. Importación de librerías para automatización de buffers.

En este caso se creó un diccionario que alojara todas las rutas de los archivos que anteriormente hemos limpiado. En el siguiente recuadro os pondré el ejemplo de 3 infraestructuras para la imagen no sea excesivamente grande y repetitiva.

```
1 # Diccionarios de infraestructuras y capas de
  referencia
2 d_infra = {
3     'depositos': {'ruta': r'C:\Users\mlain\
    proyecto_practiva_tfm\
    gdf_infraestructuras_limpios\
    GeoDataFrames_limpios_tipo_poligono\
    gdf_depositos.geojson', 'tipo': '01', 'buffer':
    15000, 'crs': 'EPSG:25830'},
4     'hospital': {'ruta': r'C:\Users\mlain\
    proyecto_practiva_tfm\
    gdf_infraestructuras_limpios\
    GeoDataFrames_limpios_tipo_poligono\
    gdf_hospitales.geojson', 'tipo': '02', 'buffer'
    : 25000, 'crs': 'EPSG:25830'},
5     'centros_salud': {'ruta': r'C:\Users\mlain\
    proyecto_practiva_tfm\
    gdf_infraestructuras_limpios\
    GeoDataFrames_limpios_tipo_poligono\
    gdf_centros_salud.geojson', 'tipo': '03', '
    buffer': 10000, 'crs': 'EPSG:25830'}
6 }
```

Figura 120. Creación de diccionario con infraestructuras y capas de referencia.

Un paso no menos importante es la creación de la ruta de salida donde queremos que todos nuestros archivos de las capas con sus respectivos buffer queden guardados.

```
1 # Ruta de la carpeta de salida
2 output_folder = r'C:\Users\mlain\proyecto_practiva_tfm
  \buffers_infras'
3 if not os.path.exists(output_folder):
4     os.makedirs(output_folder)
```

Figura 121. Creación de ruta de salida donde se guardaran nuestros buffers de cada capa de infraestructuras.

Para finalizar este script de creación automatizada de los buffers se itera en cada llave del diccionario y en cada valor es la forma en la que se debe de realizar los procesamientos cuando encapsulamos algo en diccionarios. Se asegura que el CRS es el adecuado para nuestro proyecto y se aplica el buffer. Además se quiso añadir una columna llamada `conta_tipo` con la cual se ordena cada elemento de todas las infraestructuras, se le pone un código para saber de qué elemento se trata dentro de cada infraestructura. Y posteriormente se agrega la columna `conta_tipo` con el buffer aplicado a cada una de ellas y finalmente se guardan en un archivo en formato GeoJSON.

```

1  # Procesar cada infraestructura, aplicar el buffer y
    guardar el resultado
2  for key, value in d_infra.items():
3      # Leer el archivo GeoJSON
4      gdf = gpd.read_file(value['ruta'])
5
6      # Asegurarse de que el CRS es correcto
7      if gdf.crs != value['crs']:
8          gdf = gdf.to_crs(value['crs'])
9
10     # Aplicar el buffer
11     gdf_buffered = gdf.copy()
12     gdf_buffered['geometry'] = gdf_buffered.geometry.
        buffer(value['buffer'])
13
14     # Agregar la columna 'conta_tipo'
15     gdf['conta_tipo'] = gdf.groupby('tipo').cumcount()
        + 1
16     gdf['conta_tipo'] = gdf.apply(lambda row: f"{value
        ['tipo']}_{str(row['conta_tipo']).zfill(7)}",
        axis=1)
17
18     # Agregar 'conta_tipo' al GeoDataFrame con buffers
19     gdf_buffered = gdf_buffered.merge(gdf[['id', '
        conta_tipo']], on='id')
20
21     # Guardar el GeoDataFrame con el buffer aplicado
        en un archivo GeoJSON
22     output_path = os.path.join(output_folder, f"{key}
        _buffer.geojson")
23     gdf_buffered.to_file(output_path, driver='GeoJSON'
        )
24
25     print("Buffers creados y guardados correctamente.")

```

Figura 122. Procesar cada infraestructura, aplicar el buffer columna geometry y agregar la columna conta_tipo y guardar el GeoDataFrame en archivo GeoJSON.

Para finalizar este archivo se convirtió a un archivo .py que son los archivos guardados en formato Python para ejecutarlo desde la línea de comandos (CMD). Este enfoque no solo optimizó el uso de los recursos del sistema sino que también mejoró considerablemente la velocidad de procesamiento.

Python permite ejecutar dichos procesos directamente desde la línea de comandos permitiendo un mejor manejo de los recursos del sistema, evitando los problemas de memoria asociados con entornos interactivos como Jupyter Notebook. Esta separación de procesos intensivos en memoria en scripts ejecutables mejora la velocidad de procesamiento. La metodología es escalable, con un solo script con todas las rutas de mis archivos, obtuve todos mis buffers en archivos GeoJSON de cada infraestructura en una carpeta seleccionada.

```

jupyter nbconvert --to script
    Creacion_buffers_infras_conta_tipo.ipynb

python Creacion_buffers_infras_conta_tipo.py

```

Figura 123. Script ejecutado desde la cmd o línea de comando para convertir archivo .ipynb a .py.

4.5. Script final de Python para la combinación de infraestructuras y obtención número de afectados en cada escenario regional.

En esta parte del estudio, se utiliza la lógica de la programación para desarrollar todo el modelo que finalmente obtendrá estas zonas de máximo riesgo cuando se introduzcan los datos de las distintas infraestructuras que queramos estudiar. Las zonas de influencia de cada infraestructura cambian dependiendo de la gravedad de esas afecciones. Se desarrollaran distintos escenarios teóricos de ataques a infraestructuras por posibles terroristas, ataques cibernéticos o desastres nucleares. La integración de técnicas de análisis geoespacial con modelos de evaluación de vulnerabilidad proporciona un marco robusto para evaluar los impactos a estas infraestructuras para mitigar posibles interrupciones. (Pant, Hall, & Blainey, Natural Hazards).

El primer paso siempre que estemos trabajando con Jupyter Notebook es la importación de las librerías necesarias para manipular datos geoespaciales, como son las ya comentadas GeoPandas y Pandas para manipular y analizar los datos. Una de las librerías más especiales de esta parte es intertools, es la que nos permite crear combinaciones eficientes. De Matplotlib ya se ha hablado anteriormente de ella. Otra librería es os para interactuar con el sistema de archivos que es de gran utilidad ya que te permite rastrear tus archivos.

```
1 import geopandas as gpd
2 import pandas as pd
3 import intertools
4 import matplotlib.pyplot as plt
5 import os
6 from shapely.geometry import Point, LineString,
   Polygon
7 import folium
8 import numpy as np
```

Figura 124. Importación de librerías para las combinaciones de infraestructuras.

La sección siguiente del código trata sobre definir las rutas de archivos y diccionarios. Se crean dos variables rutaInfra y ruta_buffers las cuales encapsulan y definen las rutas de los archivos que contienen los datos de infraestructuras y buffers. Posteriormente se crean dos diccionarios, uno contiene la ruta con el tipo de infraestructuras ya limpiada por los anteriores scripts y con los correspondientes buffers de cada una dependiendo de la peligrosidad y el crs unitario para todas ellas que depende de nuestra zona de estudio en nuestro caso es el EPSG: 25830. El otro diccionario contiene la ruta de las capas de España y municipios.

```

1  irutaInfra = r'C:\Users\samue\AppData\Roaming\Python\
   Python39\Scripts\TFG-TFM\
   gdf_infraestructuras_limpios-20240603T095547Z-001\
   gdf_infraestructuras_limpios\
   GeoDataFrames_limpios_tipo_poligono/'
2  ruta_buffers = r'C:\Users\samue\AppData\Roaming\Python
   \Python39\Scripts\TFG-TFM\buffers_infras-20240603
   T095541Z-001\buffers_infras/'
3
4  d_infra = {
5      'universidades': {
6          'ruta': r'C:\Users\samue\AppData\Roaming\
   Python\Python39\Scripts\TFG-TFM\
   gdf_infraestructuras_limpios-20240603
   T095547Z-001\gdf_infraestructuras_limpios\
   GeoDataFrames_limpios_tipo_poligono\
   gdf_universidades.geojson',
7          'tipo': 17,
8          'buffer': 25000,
9          'crs': 'EPSG:25830'
10     }
11 }
12
13 d_capas_ref = {
14     'ruta_municipios': {
15         'ruta': r'C:\Users\samue\AppData\Roaming\
   Python\Python39\Scripts\TFG-TFM\CapaEspaña\
   municipios.gpkg',
16         'tipo': '19',
17         'buffer': 0,
18         'crs': 'EPSG:25830'
19     },
20     'capa_españa': {
21         'ruta': r'C:\Users\samue\AppData\Roaming\
   Python\Python39\Scripts\TFG-TFM\CapaEspaña\
   capa_españa.gpkg',
22         'tipo': '20',
23         'buffer': 0,
24         'crs': 'EPSG:25830'
25     }
26 }

```

Figura 125. Creación de los diccionarios que encapsulan nuestros datos para el estudio.

El paso posterior es la creación de una función para cargar todos los GeoDataFrames desde una ruta específica que en pasos anteriores habíamos limpiado y transformado a tipo polígonos para eliminar errores de trabajar con multitud de geometrías y realizar varias operaciones a la vez.

La primera es verificar si la ruta existe con un `if not os.path.exists(ruta)` posteriormente se carga el archivo GeodataFrame se le establece el crs aunque lo tiene establecido anteriormente, nos aseguramos que la columna tipo es del tipo correcto y por último se crea una nueva columna `tipo_idx` que combina el tipo con el id de cada elemento.

```

1 def cargar_gdf(ruta, d_infra, k):
2     try:
3         if not os.path.exists(ruta):
4             print(f"Ruta no encontrada: {ruta}")
5             return None
6
7         gdf = gpd.read_file(ruta, encoding='utf-8')
8         gdf.crs = 'EPSG:25830'
9
10        # Asegurarse de que la columna 'tipo' es del
11        # tipo correcto
12        gdf['tipo'] = str(d_infra[k]['tipo'])
13
14        # Crear la columna 'tipo_index'
15        if 'id' in gdf.columns:
16            gdf['tipo_index'] = gdf['tipo'] + '_' +
17                                gdf['id'].astype(str).str.zfill(6)
18        else:
19            gdf['tipo_index'] = gdf['tipo'] + '_' +
20                                gdf.index.astype(str).str.zfill(6)
21
22        print(f"Archivo cargado correctamente: {ruta}")
23        return gdf
24
25    except Exception as e:
26        print(f"Error al cargar el archivo {ruta}: {e}")
27        return None

```

Figura 126. Creación de la función que carga los gdf.

La sección cuatro se le podría denominar la carga de elementos con la idea de transformarlos en gdf para un mejor manejo y añadirlos a una lista vacía creada con anterioridad donde finalmente se concatenaran. Para este paso necesitamos primero crear una lista llamada gdfs que almacena los GeoDataFrames cargados, esta parte se consigue implementando un for key, value in d_infra.items que va a iterar en el diccionario va a ir leyendo y cargando cada archivo de esas infraestructuras limpias y añadiéndola a la lista. Posteriormente se añade una nueva columna al GeoDataFrame que vamos a cargar llamada tipo, se le asigna el valor correspondiente que tiene dentro del diccionario y le añade otra columna con el nombre_tipo.

```

1 gdfs = []
2
3 for key, value in d_infra.items():
4     gdf = gpd.read_file(value["ruta"])
5     gdf["tipo"] = value["tipo"]
6     gdf["nombre_tipo"] = key
7     gdfs.append(gdf)
8
9 gdf_combined = gpd.GeoDataFrame(pd.concat(gdfs,
10                                           ignore_index=True))

```

Figura 127. Crear lista vacía para añadir los gdf resultantes de cada infraestructura y combinarlos.

Cuando todos los gdfs están combinados, es ahora de la limpieza y preparación de todos ellos para armonizar todos los datos. Se crea una variable nueva la cual serán las columnas que se van a eliminar ya que no las necesitamos para nuestro estudio y es ruido que puede causar alteraciones en nuestro código. Posteriormente a la variable gdfs combinada se le hace un drop para eliminar esas columnas que no queremos y en el atributo columns se pone nuestra variable con las columnas que queremos eliminar todo ello dentro de un try except por si tenemos algún error. Para finalizar con esta parte de la celda se crea una nueva columna llamada conta_tipo que lo que hace es enumerar todos los elementos de cada infraestructura por el número de la columna tipo y le añade unos ceros porque va a contar cada uno de los elementos así sabremos posteriormente que elemento de cada infraestructura tenemos en cada combinación y podremos determinar en cada combinación que elementos están involucrados.

```
1 columns_to_drop = ['x', 'y', 'etiqueta', 'desc_cod_municipio', 'sup_km2']
2 try:
3     gdf_combined = gdf_combined.drop(columns=columns_to_drop)
4 except:
5     pass
6
7 gdf_combined['conta_tipo'] = gdf_combined.groupby('tipo').cumcount() + 1
8 gdf_combined['conta_tipo'] = gdf_combined.apply(lambda row: f"{row['tipo']}_{str(row['conta_tipo']).zfill(7)}", axis=1)
```

Figura 128. Eliminación de algunas columnas sobrantes y creación de la columna conta_tipo para luego poderla concatenar con los buffers que tiene la misma columna todos ellos.

Esta sección enlaza con el script del punto 4.4 que era la automatización de la creación de los distintos buffers en las infraestructuras de manera automatiza para quitarnos procesos que son intensivos en memoria y así que pueda ir más rápido todos los demás procesos y operaciones que se realizaran en este código.

```

1 d_buffers = {
2     'depositos': 'depositos_buffer.geojson',
3     'hospital': 'hospital_buffer.geojson',
4     'centros_salud': 'centros_salud_buffer.geojson',
5     'embalse': 'embalse_buffer.geojson',
6     'lineas_electricas': 'lineas_electricas_buffer.
7         geojson',
8     'autopistas': 'autopistas_buffer.geojson',
9     'red_hidrológica': 'red_hidrológica_buffer.geojson
10     ',
11     'eolicas': 'eolicas_buffer.geojson',
12     'hidroeléctrica': 'hidroeléctrica_buffer.geojson',
13     'nuclear': 'nuclear_buffer.geojson',
14     'solar': 'solar_buffer.geojson',
15     'termicas': 'termicas_buffer.geojson',
16     'aeropuertos': 'aeropuertos_buffer.geojson',
17     'estaciones_tren': 'estaciones_tren_buffer.geojson
18     ',
19     'puertos': 'puertos_buffer.geojson',
20     'universidades': 'universidades_buffer.geojson',
21     'zonas_militares': 'zonas_militares_buffer.geojson
22     ',
23 }

```

Figura 129. Creación del diccionario con las rutas de los buffers de cada infraestructura.

Básicamente se crea un diccionario que contiene las rutas a los archivos GeoJSON que fueron creados con el anterior script que contiene los buffers de distintas distancias de todas las infraestructuras críticas. Cada clave es el nombre de la infraestructura y cada valor es la ruta al archivo correspondiente. Seguidamente se crea una lista vacía llamada `gdf_combined_buffers_list` que almacena los GeoDataFrames de los buffers.

Una vez tenemos nuestro diccionario lo que se hizo fue iterar `for filename in os.listdir(ruta_buffers)` sobre los archivos en el directorio de buffers. Pusimos una verificación para que el archivo tenga una extensión GeoJSON ya que todos nuestros buffers fueron guardados en este formato por sus múltiples beneficios. Se construye la ruta completa al archivo `filepath = os.path.join(ruta_buffers, filename)`, para luego cuando está en la ruta designada cargar el archivo GeoJSON como un GeoDataFrame `gdf = gpd.read_file(filepath)` para luego añadir una columna tipo con el nombre del archivo, para finalizar se utiliza la función `append` para añadir cada `gdf` a la lista creada con anterioridad `gdf_combined_buffers_list.append(gdf)`. La última operación de este trazo de código fue unir todos los `gdf` es uno solo con la función `concat`.

```

1  gdf_combined_buffers_list = []
2
3  for filename in os.listdir(ruta_buffers):
4      if filename.endswith('.geojson'):
5          filepath = os.path.join(ruta_buffers, filename
6                                  )
7          gdf = gpd.read_file(filepath)
8          # Extraer el nombre del archivo sin extensión
9          para usarlo como 'tipo'
10         tipo = os.path.splitext(filename)[0]
11         gdf['tipo'] = tipo
12         gdf_combined_buffers_list.append(gdf)
13
14 # Combinar todos los GeoDataFrames de buffers
15 gdf_combined_buffers = pd.concat(
16     gdf_combined_buffers_list, ignore_index=True)
17 gdf_combined_buffers = gpd.GeoDataFrame(
18     gdf_combined_buffers, geometry='geometry', crs
19     =25830)

```

Figura 130. Creación de una lista que guardara los gdf de los buffers y finalmente concatenarlos todos ellos y crear un GeoDataFrame final con ellos.

Se pretende en posteriores celdas de nuestro análisis combinar nuestros GeoDataFrames de infraestructuras y buffers pero anteriormente se eliminaron una serie de columnas que no se necesitaban. Para ello se creó una variable con una lista de columnas que se eliminaran del GeoDataFrame combinado. Luego con la variable de gdf_combinado_buffers se le aplica la función drop y dentro nuestra variable con las columnas que queremos borrar para que no estén presentes en nuestro gdf final.

```

1  columns_to_drop = ['x', 'desc_cod_municipio', '
2      etiqueta', 'sup_km2', 'y']
3  gdf_combined_buffers = gdf_combined_buffers.drop(
4      columns=columns_to_drop, errors='ignore')

```

Figura 131. Eliminación de columnas que no eran relevantes para nuestro estudio.

Cuando ya se tiene el gdf combinado de los buffers listo, se realiza la combinación con nuestro otro gdf de todas las infraestructuras críticas para tener uno único que contendrá cada uno de los elementos de las distintas infraestructuras con cada uno de sus buffers con sus distancias respectivas. Esto se consigue porque como se explicó en el punto 4.3 y 4.4 del presente trabajo, se creó en cada uno de ellos una columna común llamada conta_tipo como clave con la cual se pudo unir ambas GeodataFrames en uno solo con la función merge. merged_gdf = gdf_combined.merge(gdf_combined_buffers[['conta_tipo', 'geometry']], on='conta_tipo', how='left') se utiliza el atributo left porque se pretenden mantener todas las filas del gdf_combined. Para que no

haya confusiones con los campos de las dos geometrías se le asigna al de los buffers el campo geometry porque va a ser con el cual se va a trabajar en todos los procesos posteriores

```
1 merged_gdf = gdf_combined.merge(gdf_combined_buffers[[
    'conta_tipo', 'geometry']], on='conta_tipo', how='
    left')
2 merged_gdf.rename(columns={'geometry_y': 'geometry'},
    inplace=True)
3 merged_gdf = gpd.GeoDataFrame(merged_gdf, crs=25830,
    geometry='geometry')
```

Figura 132. Unión de los dos gdf mediante la función merge.

Las etapas subsiguientes es donde se desarrollan los procesos más importantes en nuestro estudio, los cuales darán lugar a nuestro análisis geográfico final de las combinaciones más letales de infraestructuras críticas. Para luego poder saber dónde se encuentran las regiones en España donde si sucediera esa casuística de ataque se vería más afectada la población circundante. Así sabiendo estas regiones se pueden desarrollar planes de protección más precisos y eficientes de estas infraestructuras, buscarles nuevas localizaciones o incluso planes de evacuación rápida de la población.

El paso subsecuente es la creación de una grilla para España, la grilla se define por una serie de celdas cuadradas en este caso de estudio, ya que podrían ser de otra tipología geométrica. Las propiedades principales de una grilla son la resolución espacial, determinada por el tamaño del lado de cada celda. En el código se proporciona una variable llamada resol_lada de 40 km del lado de cada celda de la grilla la cual se puede modificar modularmente para obtener resultados más detallados o menos eso dependerá de los criterios del estudio. La modificación en la resolución de la grilla en un análisis de sistemas de información geográfica tiene profundas implicaciones en la calidad y la naturaleza del análisis espacial. La resolución de la grilla en este proyecto refleja la capacidad de nuestro trabajo para ser modular y escalable, estas dos variables son fundamentales en un SIG avanzado. Esta capacidad de cambiar la resolución de la grilla significa que el análisis puede adaptarse fácilmente a diferentes niveles de detalle según sea necesario, facilitando la adaptación a distintos escenarios a diferentes escalas geográficas (local, regional, nacional) sin la modificación de la estructura básica del modelo. También tiene la escalabilidad suficientes para manejar un aumento en el volumen de datos o cubrir áreas más grandes sin perder eficiencia. El impacto que puede tener el cambio a una resolución más alta conlleva una reducción del tamaño de las celdas, así capturaremos con mayor detalle las variaciones espaciales locales permitiendo una evaluación más precisa de la distribución de estas zonas de riesgos. Pero tendremos un desafío con la memoria al generar una mayor cantidad de datos lo que requiere más capacidad de memoria y procesamiento. Además los cálculos y el análisis se vuelven más intensivos, dos problemas que hemos tenido en este trabajo por la tecnología con la que se ha elaborado este proyecto. Al bajar la resolución es lo contrario menor cantidad de datos facilita el procesamiento

y los procesos computacionales son más rápidos. Por lo tanto hay una menor capacidad para capturar variaciones locales y detalles más finos, lo que puede llevar a conclusiones menos precisas.

En este estudio se ajustó la resolución intentando encontrar un balance óptimo entre detalle y eficiencia mostrando un entendimiento profundo de la relación entre resolución espacial y precisión analítica. Esta grilla se elaboró mediante una función con las coordenadas mínimas y máximas que definen los límites de la grilla, la resolución del lado de cada celda se define con el ancho y el alto de cada celda que va a ser la variable `resol_lado` y las listas de coordenadas `x` e `y` para los vértices de los polígonos. Posteriormente se itera en cada columna y en cada fila y se añaden los polígonos con sus coordenadas. Mediante la función `append` se añaden los polígonos a la lista para finalmente crear la grilla en una nueva variable que contendrá un `GeoDataFrame` con los distintos polígonos y el CRS 25830 que es el utilizado en todo el proyecto. La última función aquí definida pero no menos importante es la `demRadio`, proporciona el radio del círculo inscrito en cada celda de la grilla. Este radio es crucial para calcular las distancias dentro del círculo y evaluar la efectividad de las operaciones. Se calcula como la hipotenusa de un triángulo rectángulo cuyos catetos son la mitad del lado de la celda.

```
1 resol_lado = 40000
2
3 def crear_grilla(x_min, x_max, y_min, y_max,
4 resol_lado, crs="EPSG:25830"):
5     width = resol_lado
6     height = resol_lado
7     cols = list(range(int(x_min), int(x_max), width))
8     rows = list(range(int(y_min), int(y_max), height))
9     polygons = []
10    for x in cols:
11        for y in rows:
12            polygons.append(Polygon([(x, y), (x +
13                width, y), (x + width, y - height), (x,
14                    y - height)]))
15    grid = gpd.GeoDataFrame({'geometry': polygons},
16        crs=crs)
17    return grid
18
19 def dameRadio(resol_lado):
20    return np.sqrt((resol_lado/2)**2 + (resol_lado/2)
21        **2)
```

```
1 def dameRadio(resol_lado):
2     return np.sqrt((resol_lado / 2) ** 2 + (resol_lado
3         / 2) ** 2)
```

Figura 133. Creación de la función para crear la grilla en España y definición de la función `demRadio` para el radio del círculo de cada celda de la grilla.




Figura 134. Dibujo de nuestra

Por lo cual, la implementación de una grilla con celdas cuadradas, cada una con un círculo inscrito, puede tener aplicaciones prácticas significativas en operaciones militares y de seguridad. Se podrían poner varios ejemplos para visualizar mejor la filosofía de nuestro trabajo que se centra en varios principios clave que son fundamentales para el análisis espacial y la evaluación de infraestructuras críticas en diferentes escenarios regionales. Supongamos que se desea desplegar paracaidistas para proteger determinadas infraestructuras críticas en una región determinada que se determinó con nuestro proyecto que es una zona de alto riesgo por una posible combinación de ataques a estas infraestructuras que causaría la afección de mucha población circúndate. Un grupo de paracaidistas podrían ser lanzados en el centro de cada círculo con sus coordenadas precisas para asegurar que el área de operación cubra toda la celda. Las ventajas serían que se garantizaría que esta región queda protegida de manera uniforme contra ataques terroristas a estas determinadas infraestructuras. A su vez se optimiza el uso de recursos al asegurar que no haya áreas superpuestas innecesariamente.

Otro caso hipotético es una operación ofensiva que pretende destruir las infraestructuras más críticas de un país. El método sería utilizando la grilla se identificando las celdas donde se encuentran la combinación más letal de infraestructuras críticas de un país dentro de cada celda. Mediante el círculo se pueden calcular las distancias a estas infraestructuras para ser golpeadas con lanzacohetes para provocar el mayor daño posible desde la máxima distancia posible para poder huir después, sería tácticas de guerrilla pero desde la distancia. Las ventajas es que permite calcular con precisión las distancias desde el centro del círculo a cualquier infraestructura dentro de la celda. Facilitando la planificación estratégica al identificar áreas clave y optimizar el uso del armamento. Dicho en otras palabras si una infraestructura o combinación de infraestructuras está a 20 km de distancia del centro del círculo, está dentro del rango efectivo para cualquier operación de protección o intervención rápida. O supongamos que el objetivo está a 35 kilómetros de distancia del centro del círculo. Utilizando el radio, se puede ajustar el ángulo y la potencia del lanzacohetes para alcanzar el objetivo con precisión.

Proseguimos con la subsecuente celda de nuestro Jupyter Notebook donde se definen los límites de la Península Ibérica usando coordenadas en EPSG: 25830. Se crea una nueva variable llamada grilla la cual es la que utiliza la función crear grilla de polígonos dentro de los límites específicos. Para posteriormente dentro de esta grilla volver a crear una columna en la cual se calculan los centroides de los polígonos llamada círculo. Se calcula el radio de los círculos basándose en la resolución del lado y para finalizar nos aseguramos que tiene el crs correcto y que la columna geometry s usa como geometría de la grilla.

```

1 x_min, x_max = 0, 1200000 # Valores aproximados para
  la extensión este-oeste
2 y_min, y_max = 4000000, 5000000 # Valores aproximados
  para la extensión norte-sur
3
4 # Crear la grilla
5 grilla = crear_grilla(x_min, x_max, y_min, y_max,
  resol_lado)
6 grilla['circulo'] = grilla.centroid
7
8 radio = dameRadio(resol_lado)
9 grilla['geometry'] = grilla['circulo'].buffer(radio)
10 grilla['geometry'].set_crs(25830, inplace=True)
11
12 grilla.set_geometry('geometry')
13 grilla.plot()

```

Figura 135. Creación de nuestra grilla implementando la función creada anteriormente.




Figura 136. Resultado obtenido con la librería Matplotlib de nuestra grilla y sus círculos.

Se está llegando al final de la explicación de la metodología del script final, solo nos queda la carga de las capas de España y municipios. Al estar encapsulada dentro de un diccionario solo se debe crear dos variables una que busque la capa en el diccionario mediante llave-valor y otra para cargar la capa como en la (figura137)

```
1 capa_españa_ruta = d_capas_ref['capa_españa']['ruta']
2 capa_españa = gpd.read_file(capa_españa_ruta, crs
   =25830)
3
4 ruta_municipios = d_capas_ref['ruta_municipios']['ruta
   ']
5 municipios = gpd.read_file(ruta_municipios, crs=25830)
6 municipios = gpd.GeoDataFrame(municipios, geometry='
   geometry', crs=25830)
```

Figura 137. Líneas de código donde se busca la variable dentro del diccionario y se carga la capa tanto de España como de los municipios.

Para finalizar nos quedan otra de las partes más importantes de nuestro proyecto con la creación de la grilla y el círculo estas son las función que manipula las combinaciones y la que evalúa la grilla guardando los resultados en archivos csv para luego poder plasmar nuestros resultado en mapas para una mejor comprensión de los datos.

La primera función trata sobre cómo se van a procesar las combinaciones de infraestructuras y realizar los cálculos de los afectados. Como en la gran mayoría de nuestras funciones se crea una lista llamada lelementos para almacenar los GeoDataFrames filtrados. Se itera sobre cada elemento de la combinación con esta parte `ele_a_verif = filtered_gdf[filtered_gdf['conta_tipo'] == elemento]` se filtra por la columna `conta_tipo` y se añade el GeoDataFrame filtrado a la lista. Mediante él `if len(lelementos) > 0` se verifica si hay elementos en la lista para posteriormente crear un nuevo GeoDataFrame con las geometrías combinadas. Posteriormente superponer la geometría combinada con los municipios para identificar los municipios afectados `over = gpd.overlay(over, municipios, how='identity', keep_geom_type=False)`. Luego se calculan los afectados basándose en el área y la densidad de población que se transforma en habitantes mediante esta variable `afectados = (over.geometry.area / 1000000 * over['DENSIDAD']).sum()`. Se selecciona el primer elemento de la combinación si no hay elementos en la lista, los afectados son 0 y la combinación NAN y retornamos la combinación y el número de afectados.

```

1 def manipula_combinacion(filtered_gdf, combinacion):
2     lelementos = []
3     for elemento in combinacion:
4         ele_a_verif = filtered_gdf[filtered_gdf['
5             conta_tipo'] == elemento]
6         lelementos.append(ele_a_verif)
7     if len(lelementos) > 0:
8         combined = gpd.GeoDataFrame(pd.concat(
9             lelementos), geometry='geometry', crs
10             =25830).unary_union
11         over = gpd.GeoDataFrame(geometry=[combined],
12             crs=25830)
13         over = gpd.overlay(over, municipios, how='
14             identity', keep_geom_type=False)
15         afectados = (over.geometry.area / 1000000 *
16             over['DENSIDAD']).sum()
17         print(afectados, combinacion)
18         combinacion = combinacion[0]
19     else:
20         afectados, combinacion = 0, np.nan
21     return afectados, combinacion

```

Figura 138. Función para manipular la combinación de las infraestructuras.

Para finalizar el script final de Python se construye una función para evaluar la grilla y calcular los afectados basándose en combinaciones de infraestructuras. Se vuelve a crear una lista vacía llamada `lresults` que va a almacenar los resultados pero ahora iterando sobre cada celda de la grilla y se crea un `GeoDataFrame` para la celda actual. Gracias a esta función `filtered_gdf = merged_gdf[merged_gdf.centroid.within(celda_g.unary_union)]` se filtra el `GeoDataFrame` que corresponda combinado para seleccionar las infraestructuras cuyo centro está dentro de la celda. Posteriormente se verifica si hay suficientes elementos para formar combinaciones y se ejecuta esta función la cual genera las combinaciones de las infraestructuras deseadas. Se itera ahora sobre elemento de la combinación para así calcular los afectados de cada combinación, si por casualidad no hubiera suficientes elementos o los afectados son 0 la combinación es NaN. Para finalmente añadir los resultados a la lista establecer el crs y devolver el `GeoDataFrame` con los resultados.


```

1 def evaluar_grilla(grilla, merged_gdf, municipios,
2   n_elementos_por_combinacion):
3     lresults = []
4     for idx, celda in grilla.iterrows():
5       celda_g = gpd.GeoDataFrame(geometry=[celda.
6         geometry], crs=grilla.crs)
7       filtered_gdf = merged_gdf[merged_gdf.centroid.
8         within(celda_g.unary_union)]
9       if len(filtered_gdf) >=
10         n_elementos_por_combinacion:
11         combinaciones = list(itertools.
12           combinations(filtered_gdf['conta_tipo'
13             ], n_elementos_por_combinacion))
14         for combinacion in combinaciones:
15           afectados, combinacion =
16             manipula_combinacion(filtered_gdf,
17               combinacion)
18       else:
19         afectados, combinacion = 0, np.nan
20         lresults.append([idx, celda_g.geometry.values
21           [0], afectados, combinacion])
22     gdf = gpd.GeoDataFrame(lresults, columns=['idx', '
23       geometry', 'afectados', 'combinacion'])
24     gdf.set_geometry('geometry', inplace=True)
25     gdf.set_crs(25830, inplace=True)
26     return gdf

```

Figura 139. Función para evaluar la grilla y calcular los afectados basándonos en las combinaciones de las infraestructuras.

Se termina con la ejecución de la evaluación de la grilla y el guardado de los resultados. Se define también la variable `n_elementos_por_combinacion = 3` con el número de elementos de infraestructuras críticas que se consideran simultáneamente en cada combinación durante el análisis. Este parámetro es significativo en nuestro estudio ya que le añade complejidad y realismo al estudio. Al analizar cuatro tres o dos elementos permiten capturar la complejidad de las interacciones y efectos en cascada que pueden surgir en situaciones reales. Este enfoque nos permite identificar combinaciones específicas que presentan el mayor riesgo permitiendo a planificadores y responsables de la toma de decisiones priorizar sus esfuerzos de mitigación y respuesta en los escenarios más críticos. Según estudios como el de Johansson y Hassel (*Journal of Infrastructure Systems*) y Pant et al. (Natural Hazards), entender estas interdependencias entre múltiples infraestructuras críticas es esencial para el desarrollo de políticas y estrategias de resiliencia.

Finalmente se llama a la función para evaluar la grilla y se guardan los resultados en csv y se crea la capa de riesgos a partir de `gdf_resultados` para posteriormente volver a guardarla.

```

1 # Especificar el número de elementos por combinación
2 n_elementos_por_combinacion = 3
3
4 # Llamar a la función para evaluar la grilla
5 gdf_resultados = evaluar_grilla(grilla, merged_gdf,
6     municipios, n_elementos_por_combinacion)
7 gdf_resultados
8
9 # Guardar los resultados en un archivo CSV
10 gdf_resultados.to_csv('resultados_depo_hospi_3.csv',
11     index=False)
12
13 # Crear la capa de riesgo a partir de 'gdf_resultados'
14 gdf_riesgo = gdf_resultados[['idx', 'geometry', '
15     afectados']].groupby(['idx', 'geometry']).max().
16     reset_index()
17 gdf_riesgo = gpd.GeoDataFrame(gdf_riesgo, geometry='
18     geometry', crs=25830)
19 gdf_riesgo['area'] = gdf_riesgo.geometry.area
20 gdf_riesgo['geometry'] = gdf_riesgo.geometry.centroid
21
22 # Guardar la capa de riesgo en un archivo CSV
23 gdf_riesgo.to_csv('riesgo_depos_hospitales.csv', index
24     =False)

```

Figura 140. Código donde se especifica el número de elementos por combinación y se llaman a las función evaluar_grilla y luego se crea la capa de riesgos máximos. Se guardan los resultados en archivos csv

5. La Generación cartografía.

Al finalizar nuestro script de Python se obtienen dos ficheros en formato csv en los cuales obtenemos los resultados y los riesgos de las combinaciones de infraestructuras críticas estudiadas en ese determinado caso hipotético. Dentro del archivo de resultados se muestran todos los círculos que creamos dentro de nuestra grilla con su respectivo idx que es la enumeración de cada uno de ellos para saber posteriormente donde se localizan además del número total de afectados máximo y la combinación más letal en cada uno de ellos. El siguiente archivo es llamado riesgos y en él se encuentra el centroide de cada uno de los círculos donde se guarda la información del idx de cada uno con su información de afectados y el área que en nuestro caso es igual para todos debido a que todas las celdas de nuestra grilla son de las mismas dimensiones aunque como se explicó en apartado 4.5 se puede cambiar la resolución de la grilla para obtener distintos análisis dependiendo de los objetivos de nuestro estudio al ser un proyecto modulable rápidamente variando solo la variable del lado de cada celda de la grilla que está en script final.

Posteriormente abrimos QGIS y añadimos nuestros ficheros mediante la opción añadir capa de texto delimitado como se presenta en la (figura 141). Cuando se ha cargado el documento csv de riesgos dentro del SIG se realiza un clic derecho en el para ir a la pestaña de propiedades de capa donde se

encuentra la opción simbología y se puede seleccionar la columna afectados en nuestro caso para posteriormente graduar en intervalos iguales para reconocer donde tenemos los puntos de mayor riesgo dándole una gama de colores. Todo este proceso se puede seguir mediante la (figura 142).

Posteriormente seleccionamos dentro de la caja de herramientas de QGIS la opción idw aunque también podríamos haber utilizado el algoritmo de los mapas de calor para la consecución del proyecto. Se decidió utilizar este algoritmo debido a la mayor precisión en la interpolación, calcula los valores en ubicaciones no muestreadas en función de la proximidad a los puntos de muestra conocidos. Se obtiene un modelo detallado que reflejara las variaciones espaciales lo que permite controlar cómo la distancia afecta la influencia de los puntos de muestra esto significa que puedes ajustar la influencia de los puntos lejanos frente a los cercanos según tus necesidades. Una de las principales ventajas por la que se decidió optar por el idw es que es más adecuado para datos heterogéneos donde los valores varían significativamente en distancias cortas. Además se buscaba algo más de precisión y detalle en nuestra distribución espacial de los datos de afectados. Por último ofrece más opciones de personalizar la interpolación por idw, ajustando número de vecinos más próximos y el peso de cada punto basado en la distancia lo que da un mayor control sobre el resultado final.

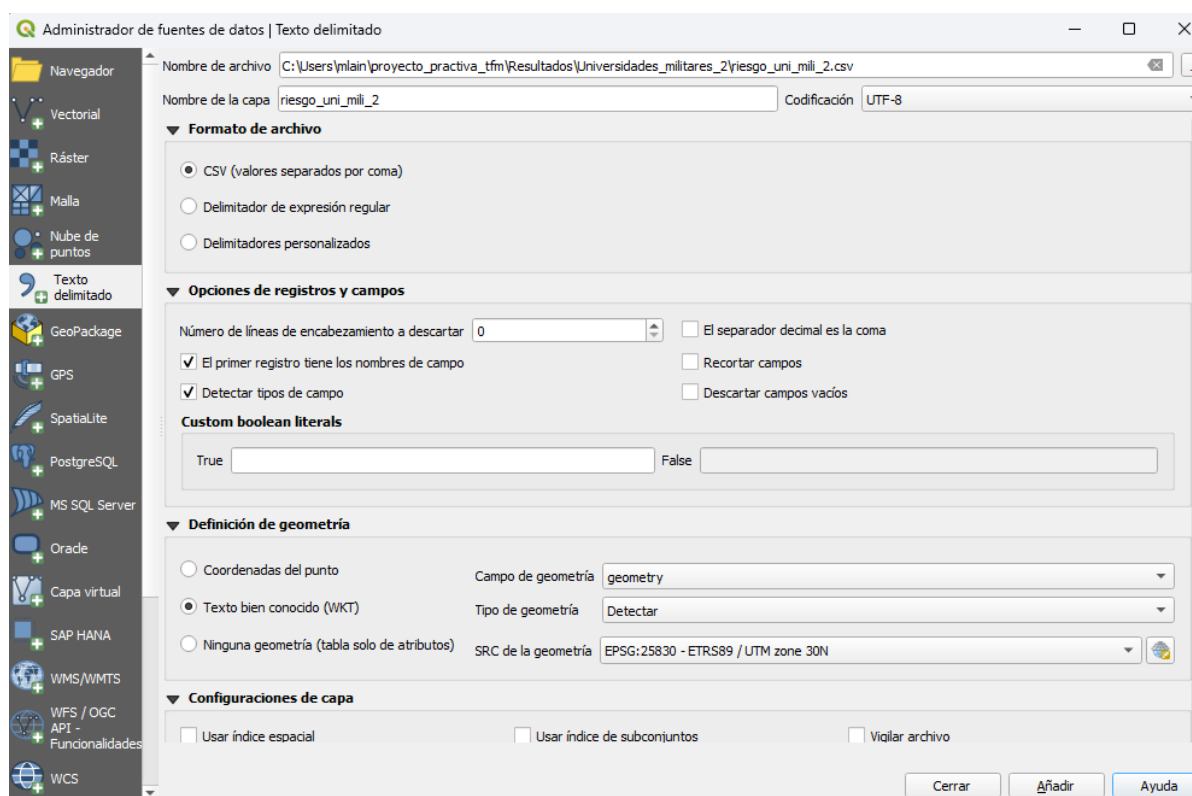


Figura 141. Proceso para añadirlos csv en QGIS mediante el menú administrador de fuentes de datos.




Figura 142. En propiedades de capa, se gradúa por la columna afectada y se le asigna la rampa de colores deseada.

Al obtener nuestro archivo raster idw, se hace clic derecho de nuevo sobre la capa para darle una simbología que en este caso el tipo de renderizado es pseudocolor monobanda. Se selecciona la rampa de colores deseada en nuestro caso la spectral, invertimos el color rojo para que se localice en los valores más altos y luego le damos un sesenta por ciento de transparencia para que se puedan ver las capas que tenemos debajo de provincias o los tipos de infraestructuras. Finalmente se le cambia el modo a cuantiles, esta técnica es utilizada en la clasificación de datos en las propiedades de la capa en un IDW (Interpolación Ponderada por el Inverso de la Distancia). Esta técnica tiene un impacto significativo en la visualización de los datos. Los cuantíales al ser puntos en una distribución de datos

dividen el rango de los datos en partes iguales con iguales números de observaciones. En nuestro caso los dividen en 4 partes iguales al ser cuantiles. Esto quiere decir que cada una de nuestras clases contiene aproximadamente el mismo número de píxeles, lo que puede resultar en una distribución visualmente más equitativa de los colores del mapa. Hay varias ventajas a destacar de este modo de cuantiles, una de ellas es la distribución equitativa de los colores asegurando que cada clase tenga un número similar de celdas de datos, lo que hace que nuestros mapas sean más fáciles de interpretar visualmente, ya que los colores están distribuidos de manera más uniforme.

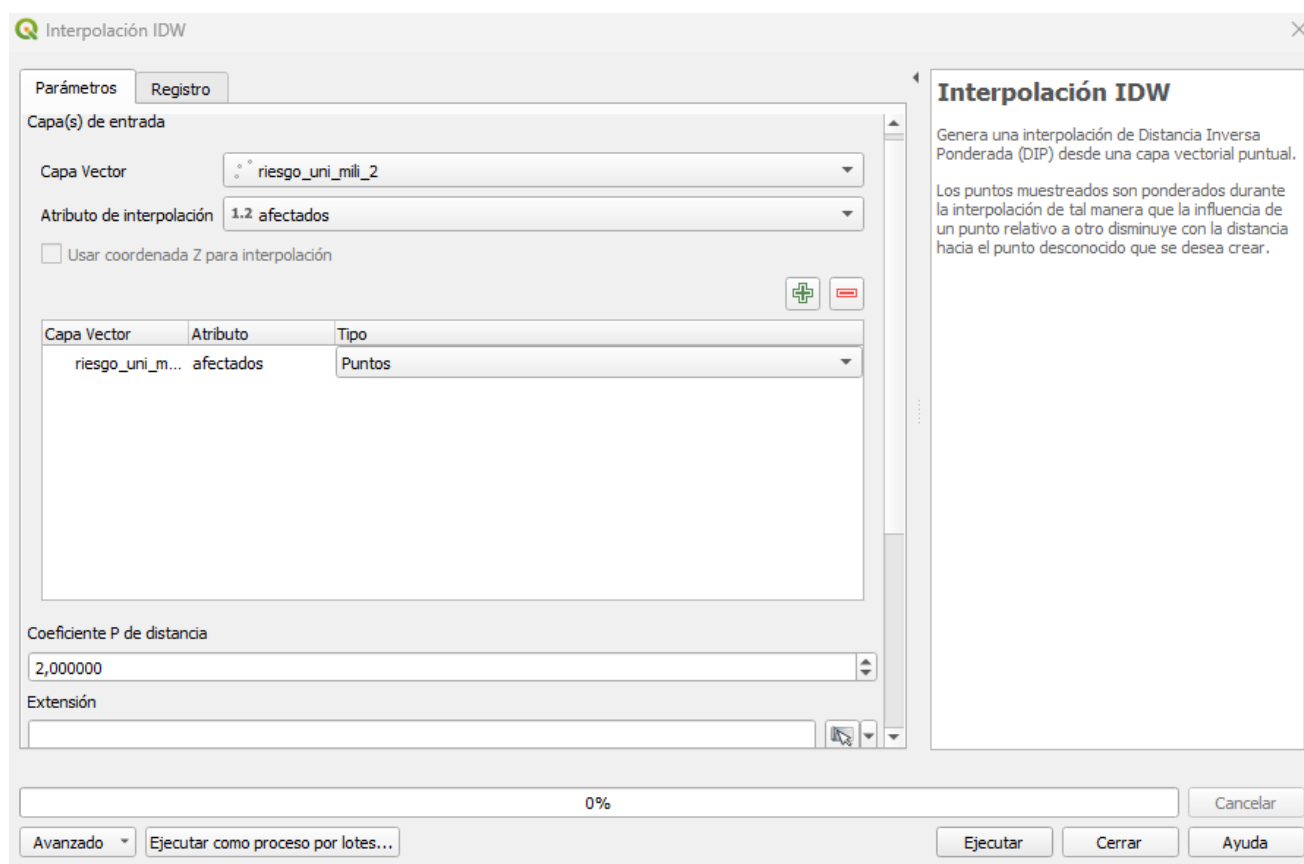


Figura 143. Dentro de la capa de herramientas encontramos el algoritmo de interpolación IDW.

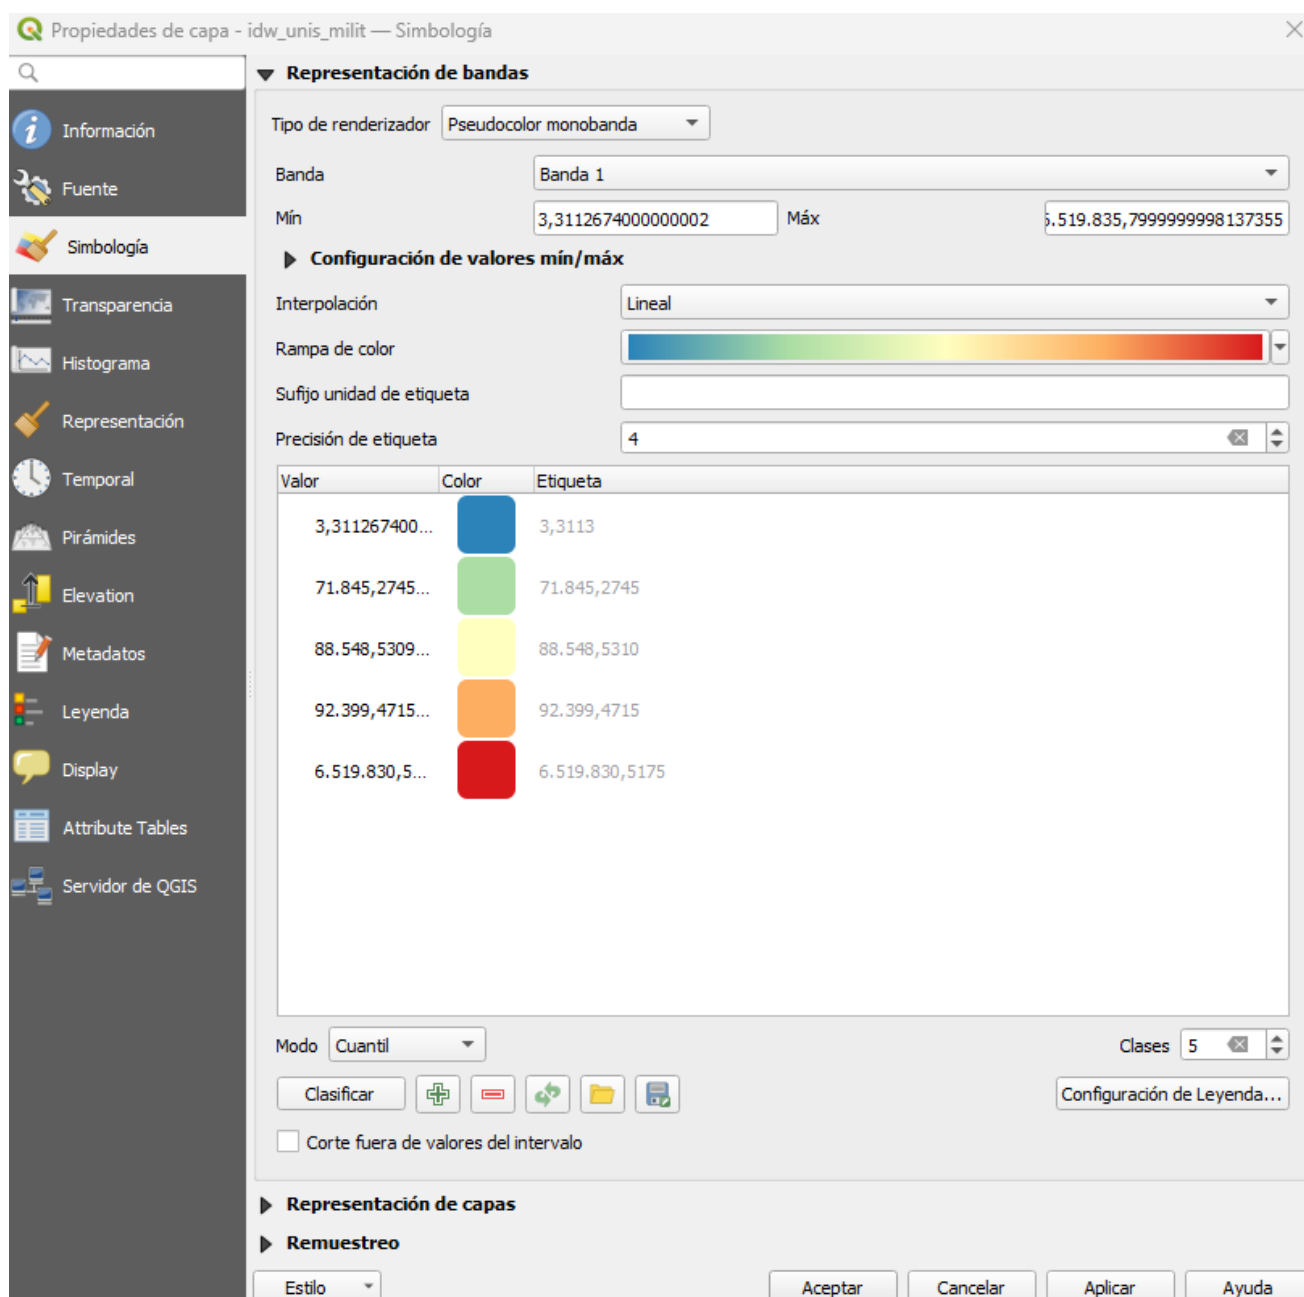
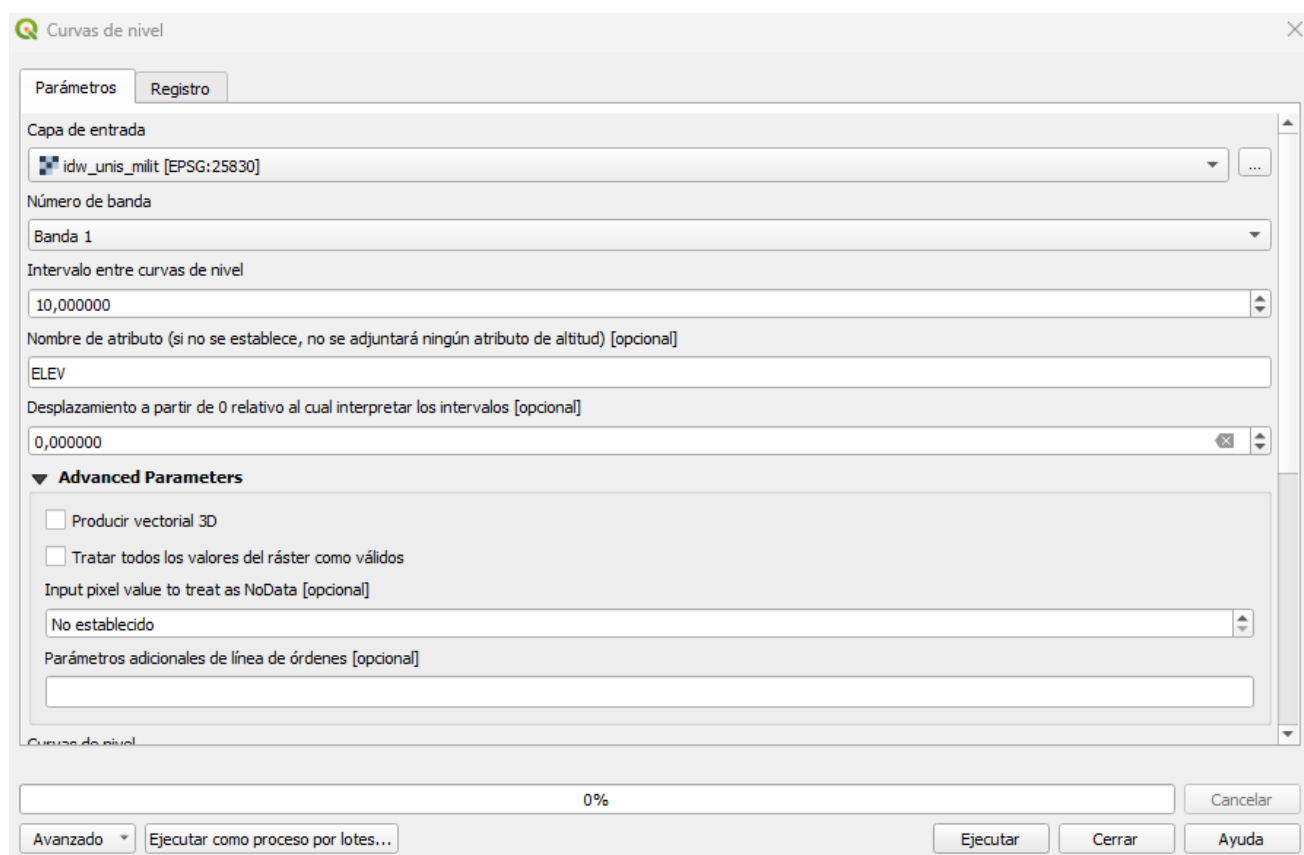


Figura 144. Las propiedades del raster IDW donde seleccionamos Pseudocolor monobanda y el modo cuantil.

Para finalizar se crean las curvas de nivel que van a representar el número de afectados de las zonas de riesgo en una determinada cantidad que se verá dependiendo de la distribución de nuestros datos. Se vuelve a ir a la caja de herramientas de QGIS para seleccionar la herramienta curvas de nivel, dentro de las opciones se selecciona el idw obtenido anteriormente y se indica el intervalo deseado en cada uno de los casos como en la (figura 145).



145. En la caja de herramientas volvemos a encontrar el algoritmo para las curvas de nivel de cada uno de nuestro IDW.

6. Resultados.

6.1. Regiones españolas de máximo riesgo de afectados por ataque de combinaciones en infraestructuras de red de transportes.

Uno de los escenarios regionales hipotéticos de mayor riesgo de afectados que más interés suscito eran las infraestructuras críticas del transporte en España. ¿Qué sucedería si se atacan simultáneamente combinaciones de determinadas infraestructura críticas del transporte, cuantas personas se verían afectadas que zonas de España serían las más críticas?

Primero me explicare porque las infraestructuras de transporte en España se distribuyen de esta manera: uno de los más determinantes es la orografía de España, que incluye montañas como los Pirineos, Sistema Ibérico, Sistema Central, la Cordillera Cantábrica, Montes de León, Montes de Toledo, Sierra Morena y Sistemas Béticos que ha influido en la localización estratégica de estas infraestructuras de transporte como se puede visualizar en la figura 146. Las zonas que son más planas como la Meseta central (Submeseta Norte y Submeseta Sur) y las llanuras costeras, son más adecuadas para el desarrollo de carreteras, vías ferroviarias, aeropuertos y puertos. Otro de los factores es el desarrollo histórico de España el cual ha dejado su sello en la distribución de las infraestructuras críticas de

transporte. Un claro ejemplo es la capital Madrid, su papel central en la historia del país se refleja en su posición de nodo central de la red de transportes, llamado sistema radial, se utiliza este término para la descripción de la configuración de las infraestructuras de transporte por carreteras, trenes y otras vías en España que parten del centro de la península ibérica y se extienden hacia las demás regiones. España al ser una península rodeada por los mares Mediterráneo, Cantabro y el océano Atlántico, los puertos representan localizaciones esenciales para el comercio internacional y están localizados en su mayoría en las costas del mar mediterráneo y Cantábrico. Los puertos de mayor importancia son los de Barcelona, Valencia y Algeciras ya que sirven de entrada y salida de mercancías hacia los puntos más importantes del planeta. Los puertos ayudan al desarrollo económico de multitud de regiones de España proporcionando puestos de trabajo y facilitando la exportación de productos locales como aceite de oliva, vino y productos industriales. Las infraestructuras de transporte se concentran densamente en áreas costeras y regiones metropolitanas, lo que indica una alta interdependencia y posibles efectos cascada en casos de fallos. Esta (figura 146) nos muestra también regiones que podrían necesitar una mayor atención en términos de planificación de nuevas infraestructuras de transporte para una mejor conexión con el resto de España y del mundo ya que nos encontramos en un mundo globalizado donde las conexiones con otras partes del planeta son de máxima importancia.

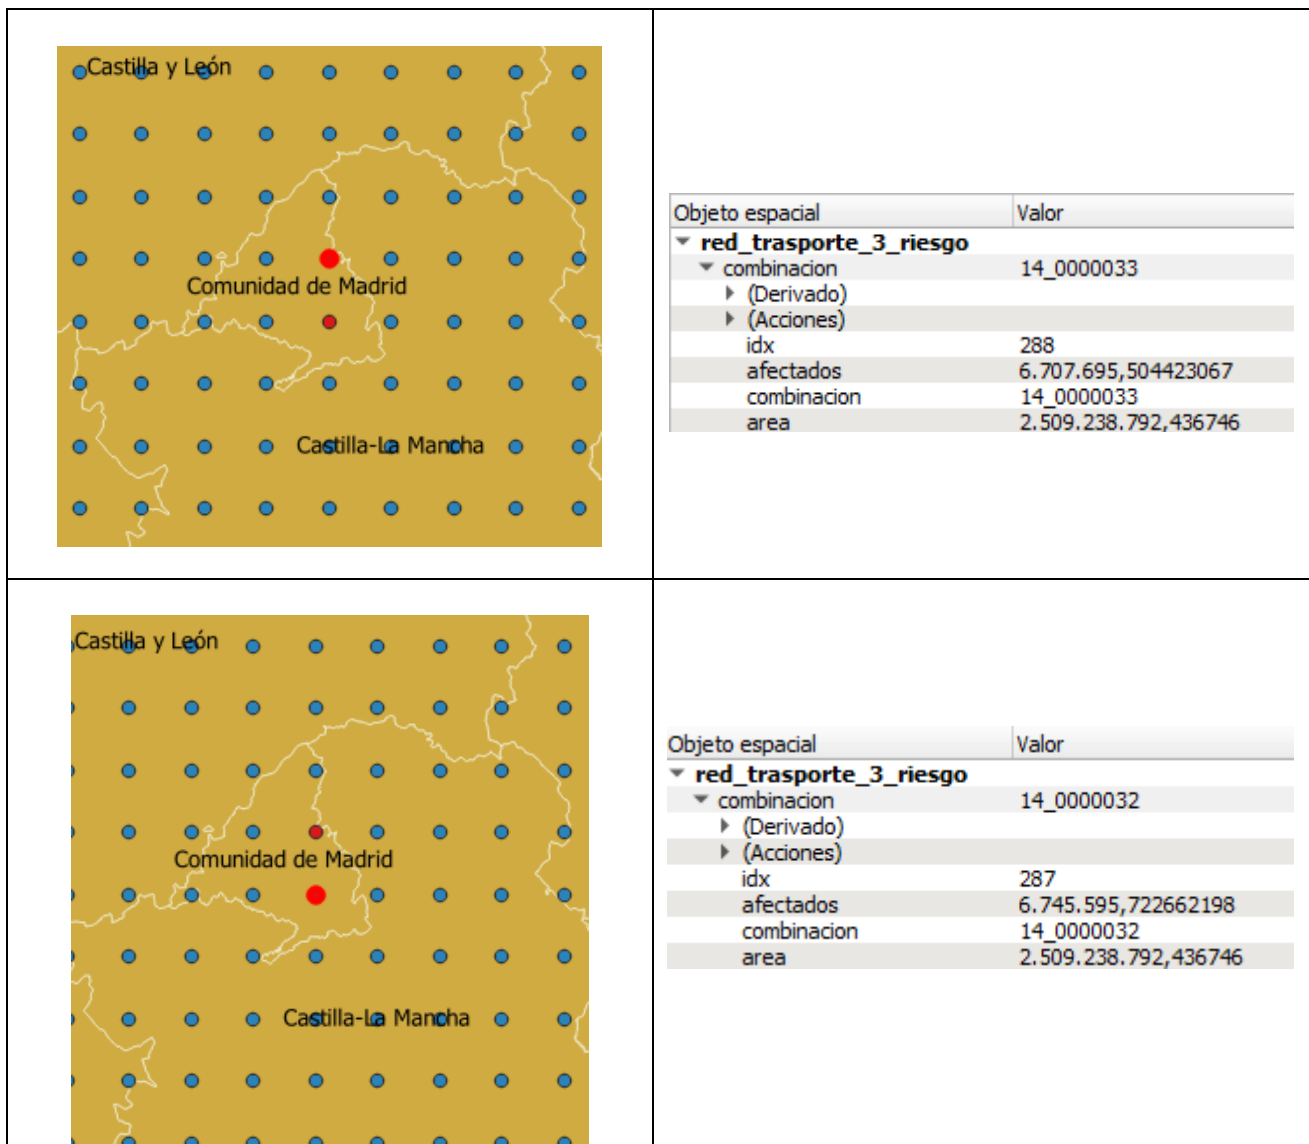


Figura 146. Localización de puertos, aeropuertos y autopistas en España que son las infraestructuras críticas utilizadas en este caso hipotéticos.

Se decidió realizar un estudio de las combinaciones de infraestructuras críticas de puertos, aeropuertos y autopistas para llegar a saber las regiones de mayor riesgo en número de personas afectadas por eventos adversos. Hubiera sido interesante añadir la red de carreteras y las estaciones de tren pero se hubiera incrementado mucho el número de elementos de las infraestructuras y el tiempo de procesamiento de todas ellas debido a las limitaciones de memoria ya comentadas anteriormente.

En la (figura 151) se muestran todas las principales regiones de España que sufrirían el mayor número de personas afectadas por una caída en masa de los servicios que proveen las infraestructuras críticas de transporte de estas regiones. Se puede visualizar que las zonas más afectadas serían la Comunidad de Madrid, Cataluña, la Comunidad Valenciana, País Vasco, Asturias, Galicia y la zona costera de Andalucía ya que muestran zonas de alto riesgo debido a la concentración de infraestructuras críticas y la alta densidad de población.

En párrafos anteriores se comentaba que las carreteras, autopistas y autovías tienen una morfología radial, salen desde Madrid al resto de España aunque en nuestro estudio solo se han seleccionado las autopistas por el incremento de elementos que añadiríamos con las carreteras y autopistas ya que necesitaríamos mayor tecnología para el procesamiento de la que se ha dispuesto en este trabajo. Por lo tanto, la principal causa del riesgo máximo en Madrid sería por la acumulación de cuatro aeropuertos en esta región que son los de mayor volumen de pasajeros, la multitud de tramos de autopistas pero el factor determinante son las altas tasas de densidad de población en estas zonas y por lo tanto ha sido el factor clave para visualizarlas como zona de máximo riesgo. Como dato interesante a apuntar en nuestros resultados son los dos centroides de la (figuras 147, 148) donde se ha guardado la información de afectados de Madrid de nuestra grilla, es aquí donde se han obtenido valores de 6.000.000 millones de afectados. Número que refleja una estimación total del número de personas que podrían verse impactadas en caso de interrupción. Esto subraya la necesidad de enfoques integrados y robustos para la gestión de infraestructuras críticas y la preparación ante emergencias.



Figuras 147, 148. Los dos centroides en Madrid con más de 6.000.000 millones de afectados.

Otra de las zonas o regiones más afectadas es la Comunidad Autónoma de Cataluña a excepción de una parte de la provincia de Lérida. Se ve afectada totalmente debido a la acumulación de aeropuertos, autopistas y puertos ya que tiene una extensa región costera con multitud de ellos tanto comerciales como de pasajeros que incrementan el riesgo de afectados en esta región de España. Esto se apreciar en las (Figura 149) donde los centroides de nuestro csv de riesgos muestran valores de más de 5.000.000 millones de afectados y seleccionamos varios de ellos en QGIS con la herramienta de información para ver en la tabla de atributos cual ha sido en número de afectados

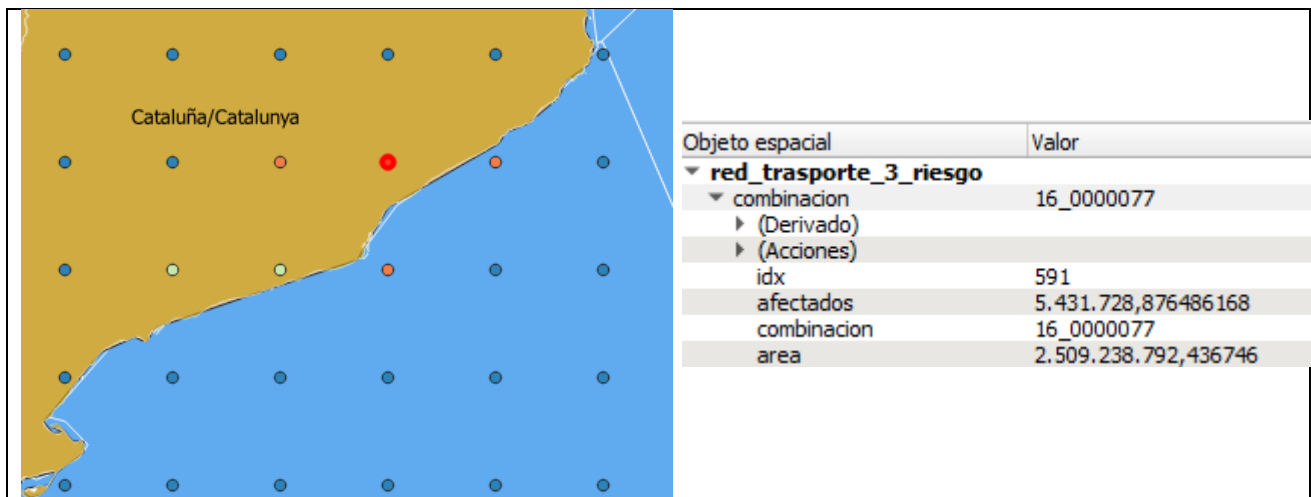


Figura 149. Afectados en los centroides de Cataluña

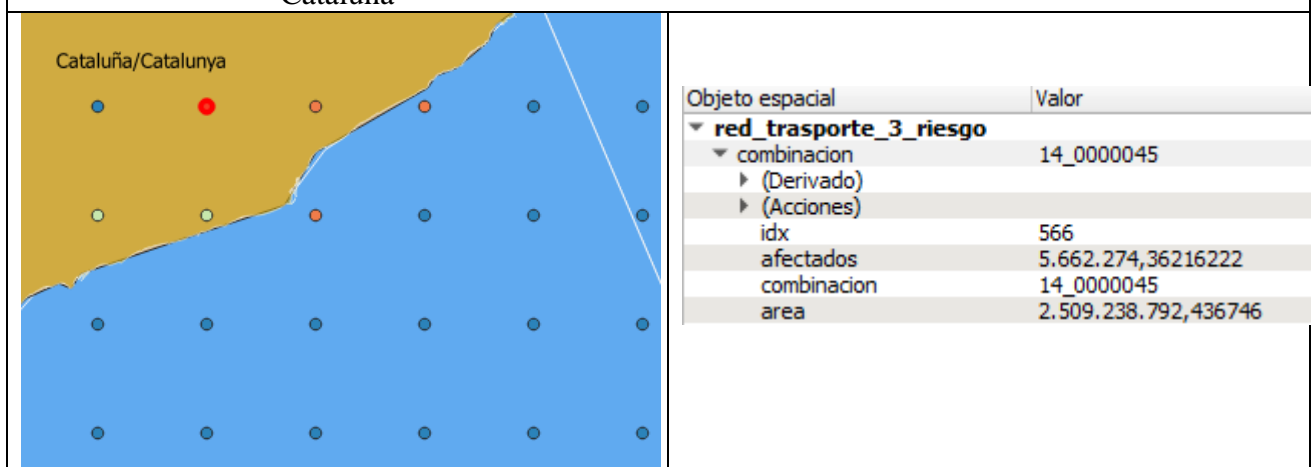


Figura 150. Afectados en centroides de Cataluña.

En la (Figura 152, 153) donde se presentan dos caso el de la costa del Mediterráneo y la Costa Cantábrica , observa un aspecto curioso y es que la influencia de estos efectos de riesgo llega incluso hasta las Islas Baleares y se extiende por el mar. Esto le viene bien a nuestra filosofía del estudio porque habíamos pensado en la posibilidad de que atacaran estas infraestructuras desde el mar con buques preparados para ello. Mediante los círculos trazados dentro de las celdas de las grillas y sabiendo el radio del círculo podemos obtener las distancias a la que llegan las bombas desde el barco podríamos calcular las distancia precisa a la cual el Estado español debería de colocar barcos de guerra para poder proteger las infraestructuras críticas de transporte en esta zona de la costa Mediterránea. Son escenarios extremos pero siempre es bueno prevenir, porque la actualidad geopolítica está candente y están surgiendo muchos conflictos que pueden afectar a España y por contrapartida a sus ciudadanos.

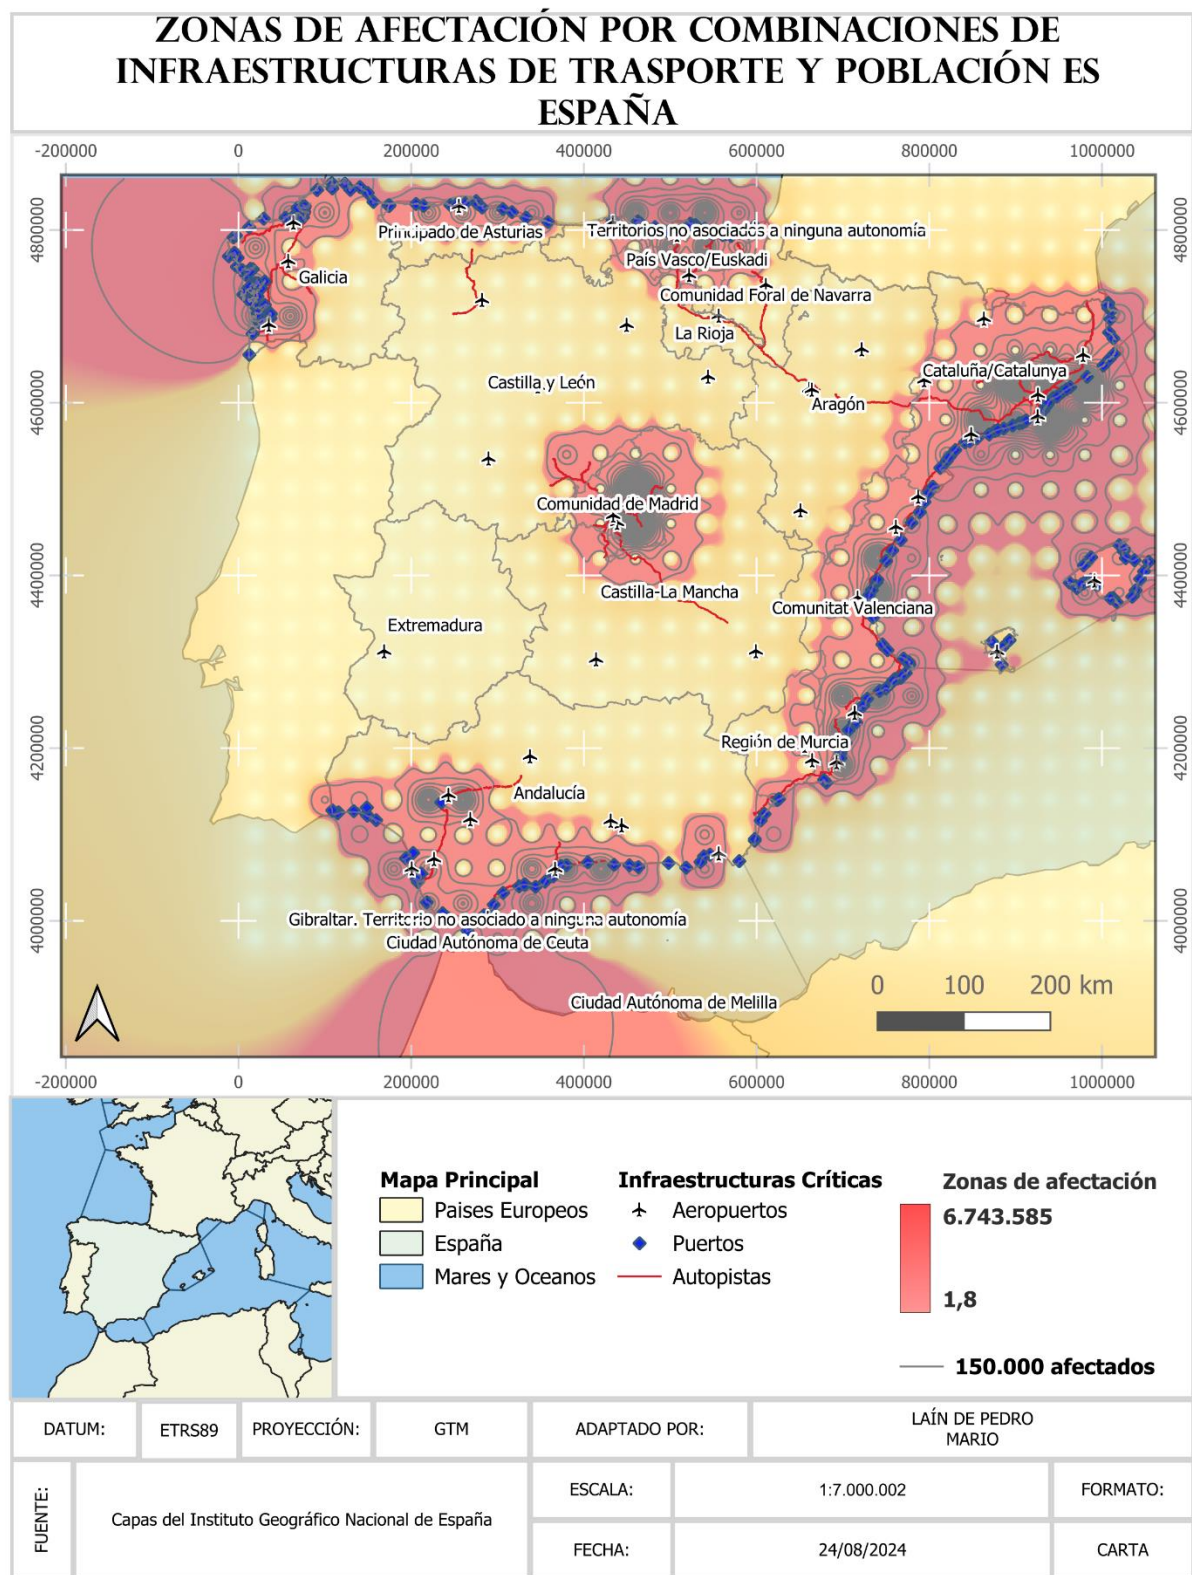


Figura 151. Regiones españolas de alto riesgo de afectados por combinaciones de infraestructuras de transporte.

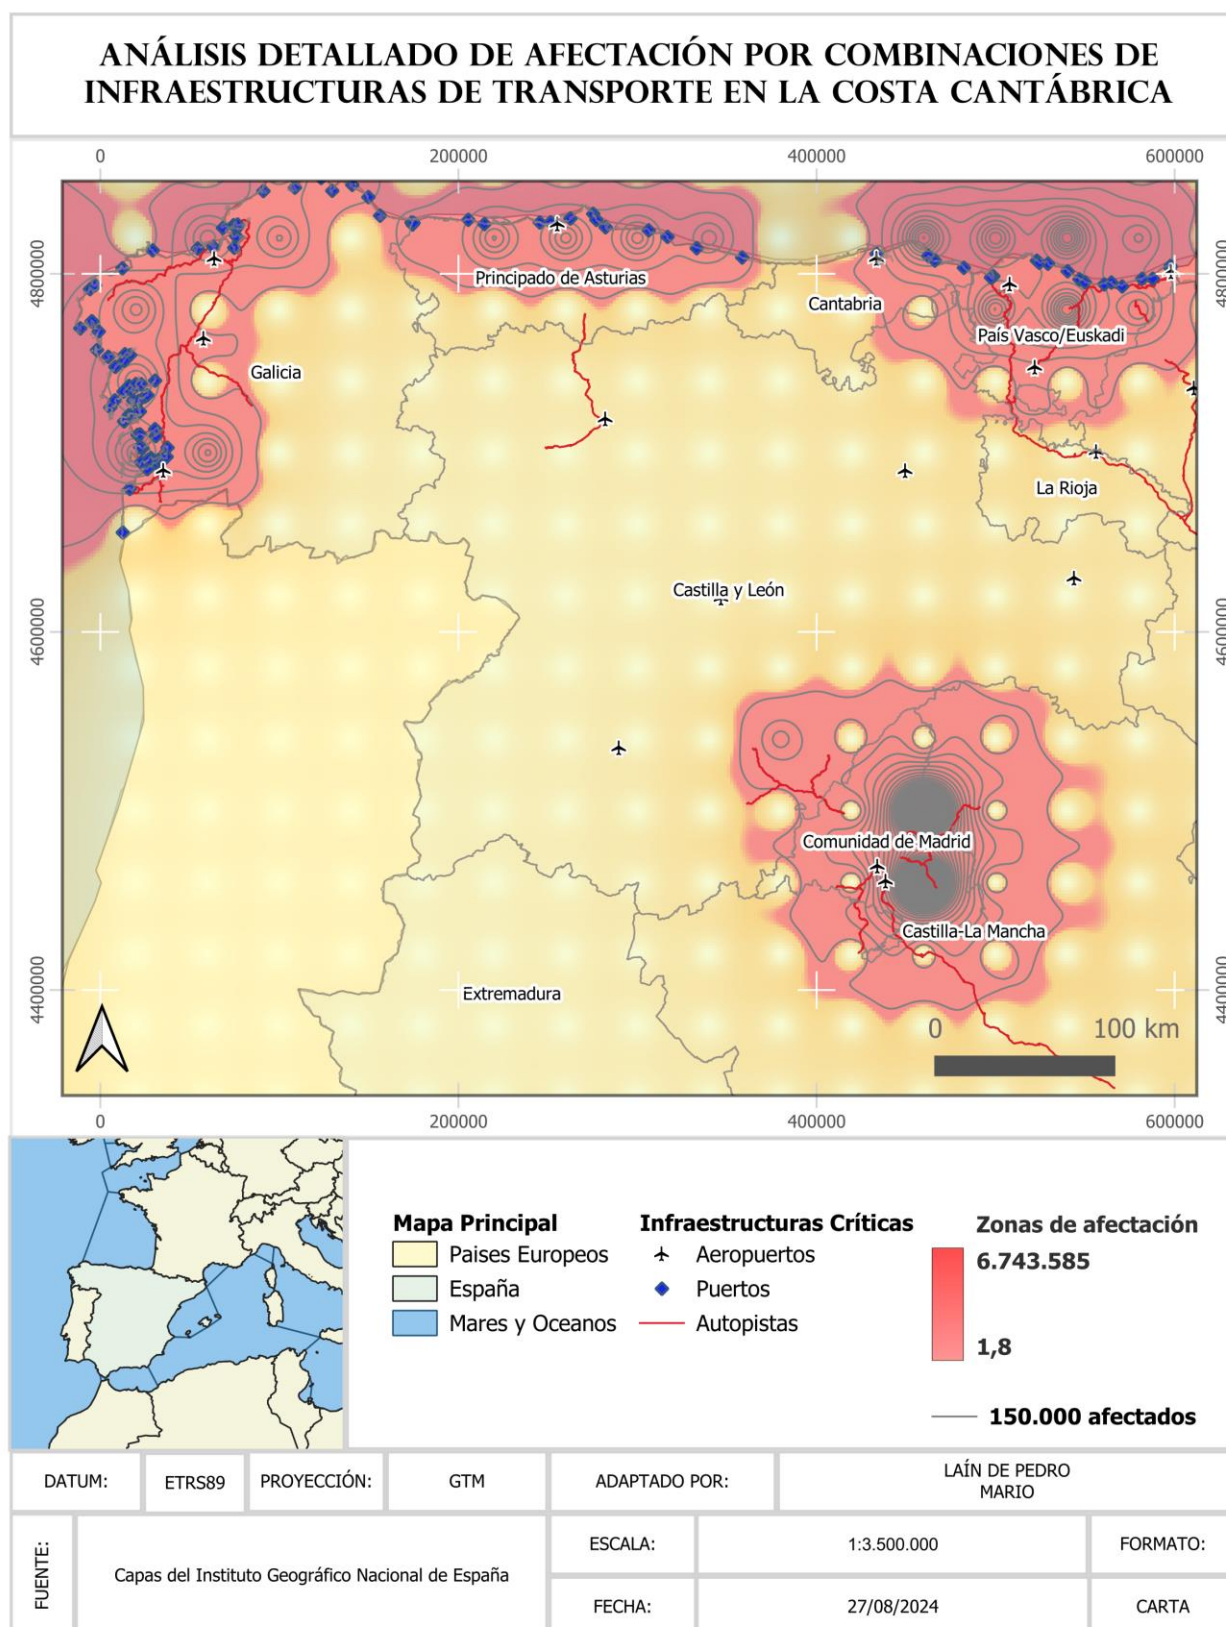


Figura 152. Análisis detallado de afectación por combinaciones de infraestructuras de transporte en la costa Cantábrica.

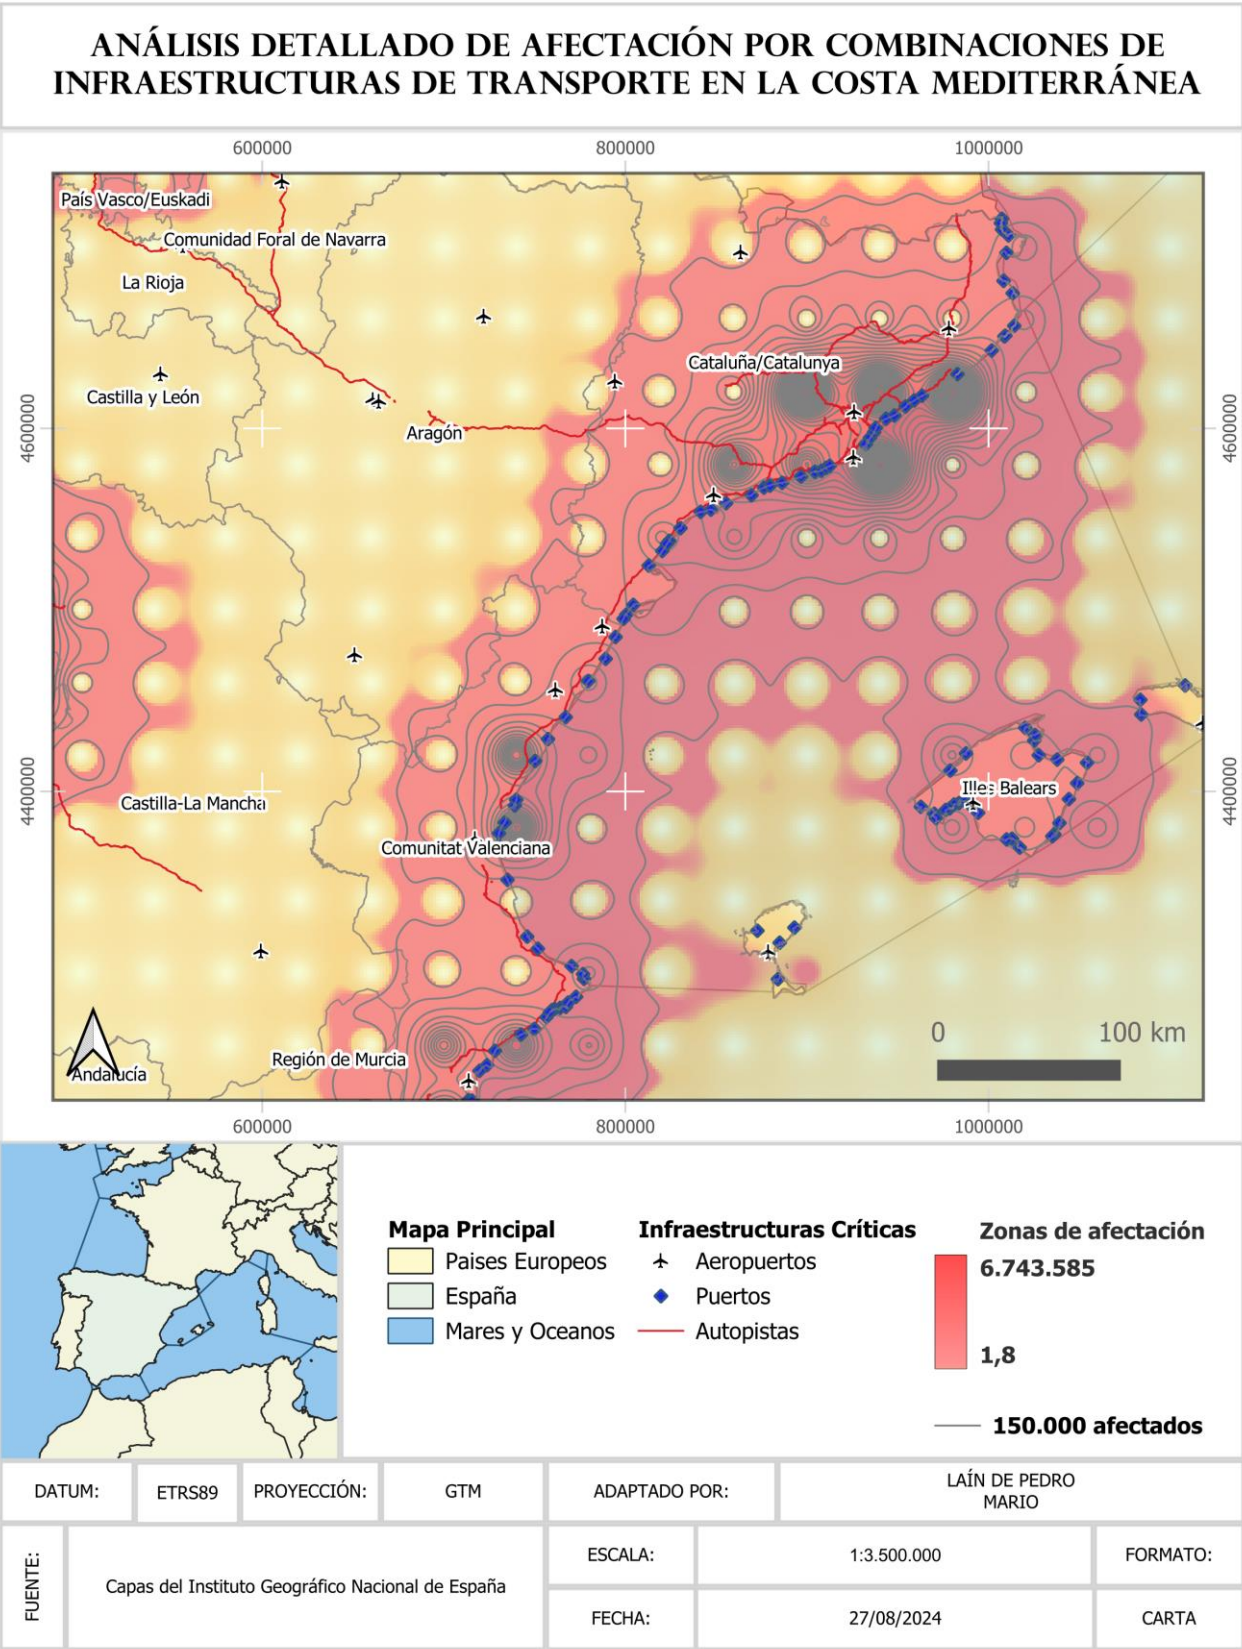


Figura 153. Análisis detallado de afectación por combinaciones de infraestructuras de transporte en la costa Mediterránea.

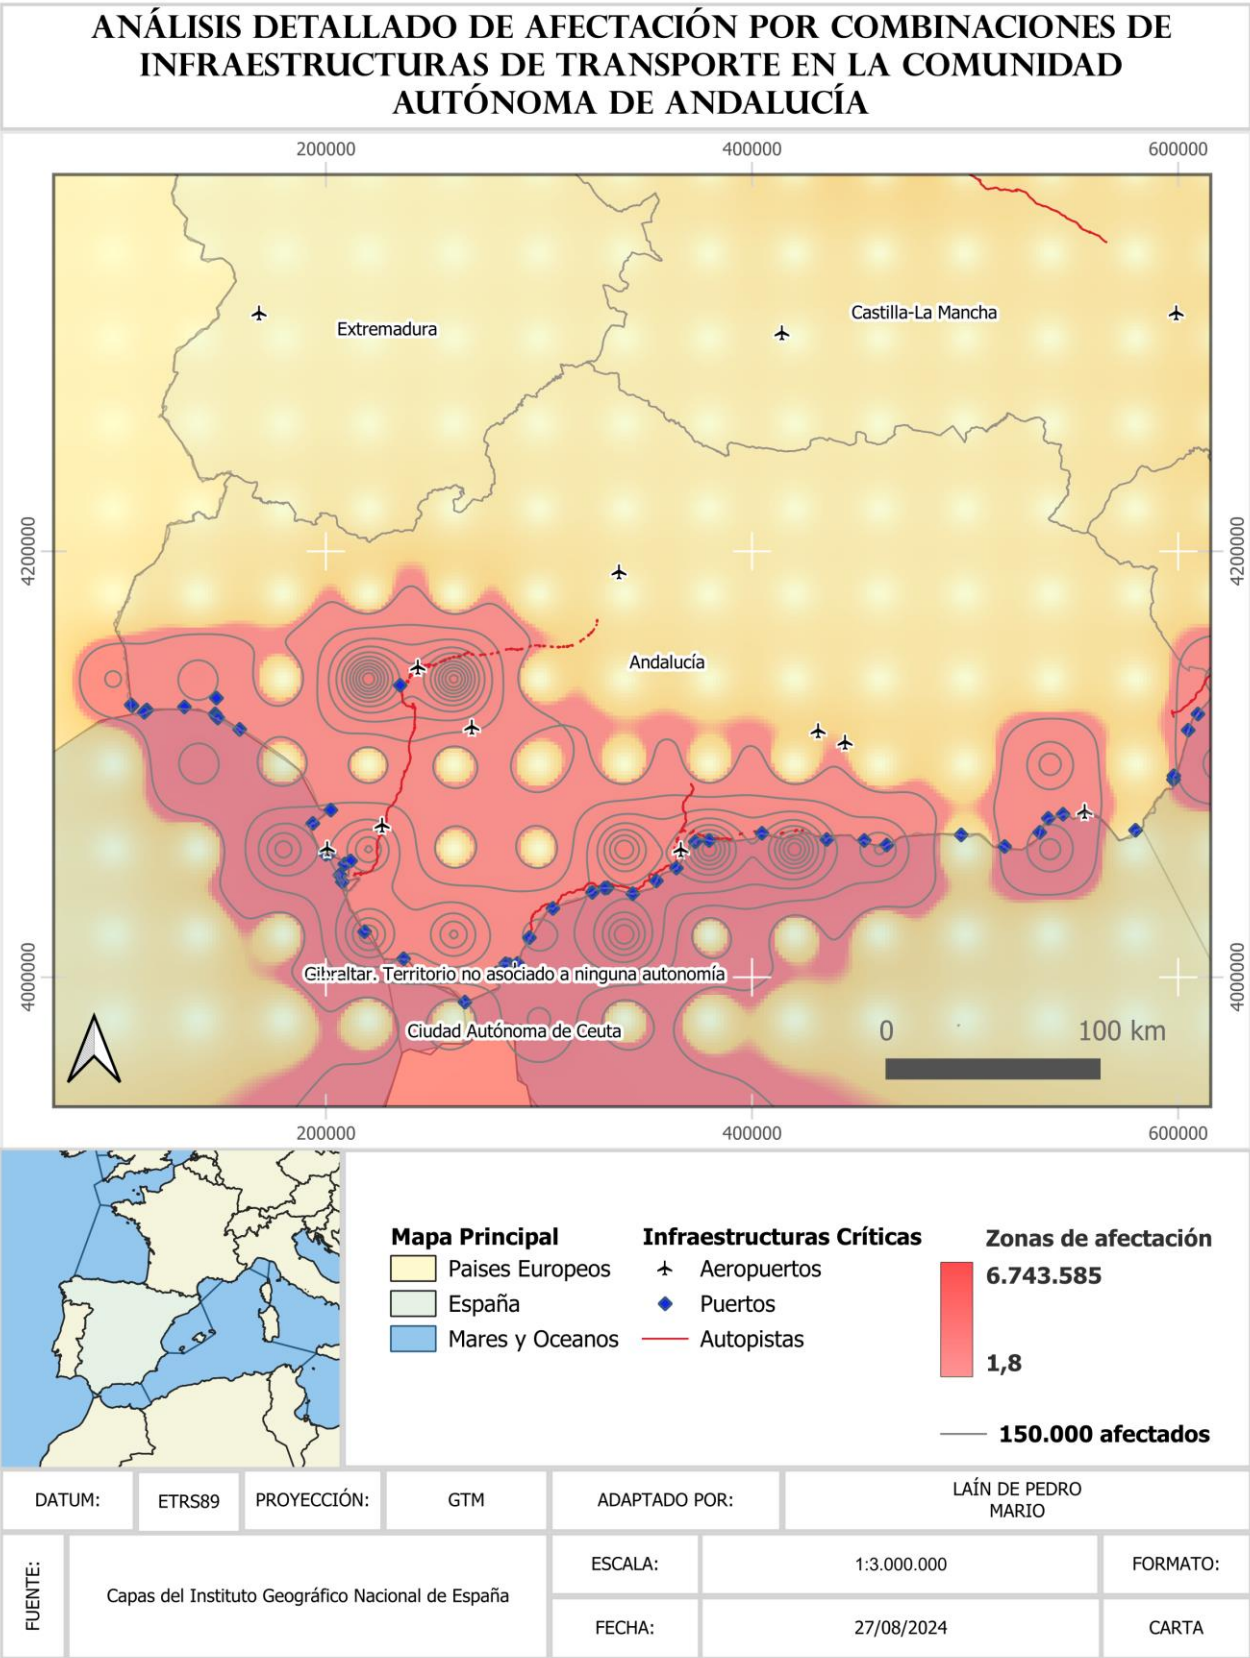


Figura 154. Análisis detallado de afectación por combinaciones de infraestructuras de transporte en la Comunidad Autónoma de Andalucía.

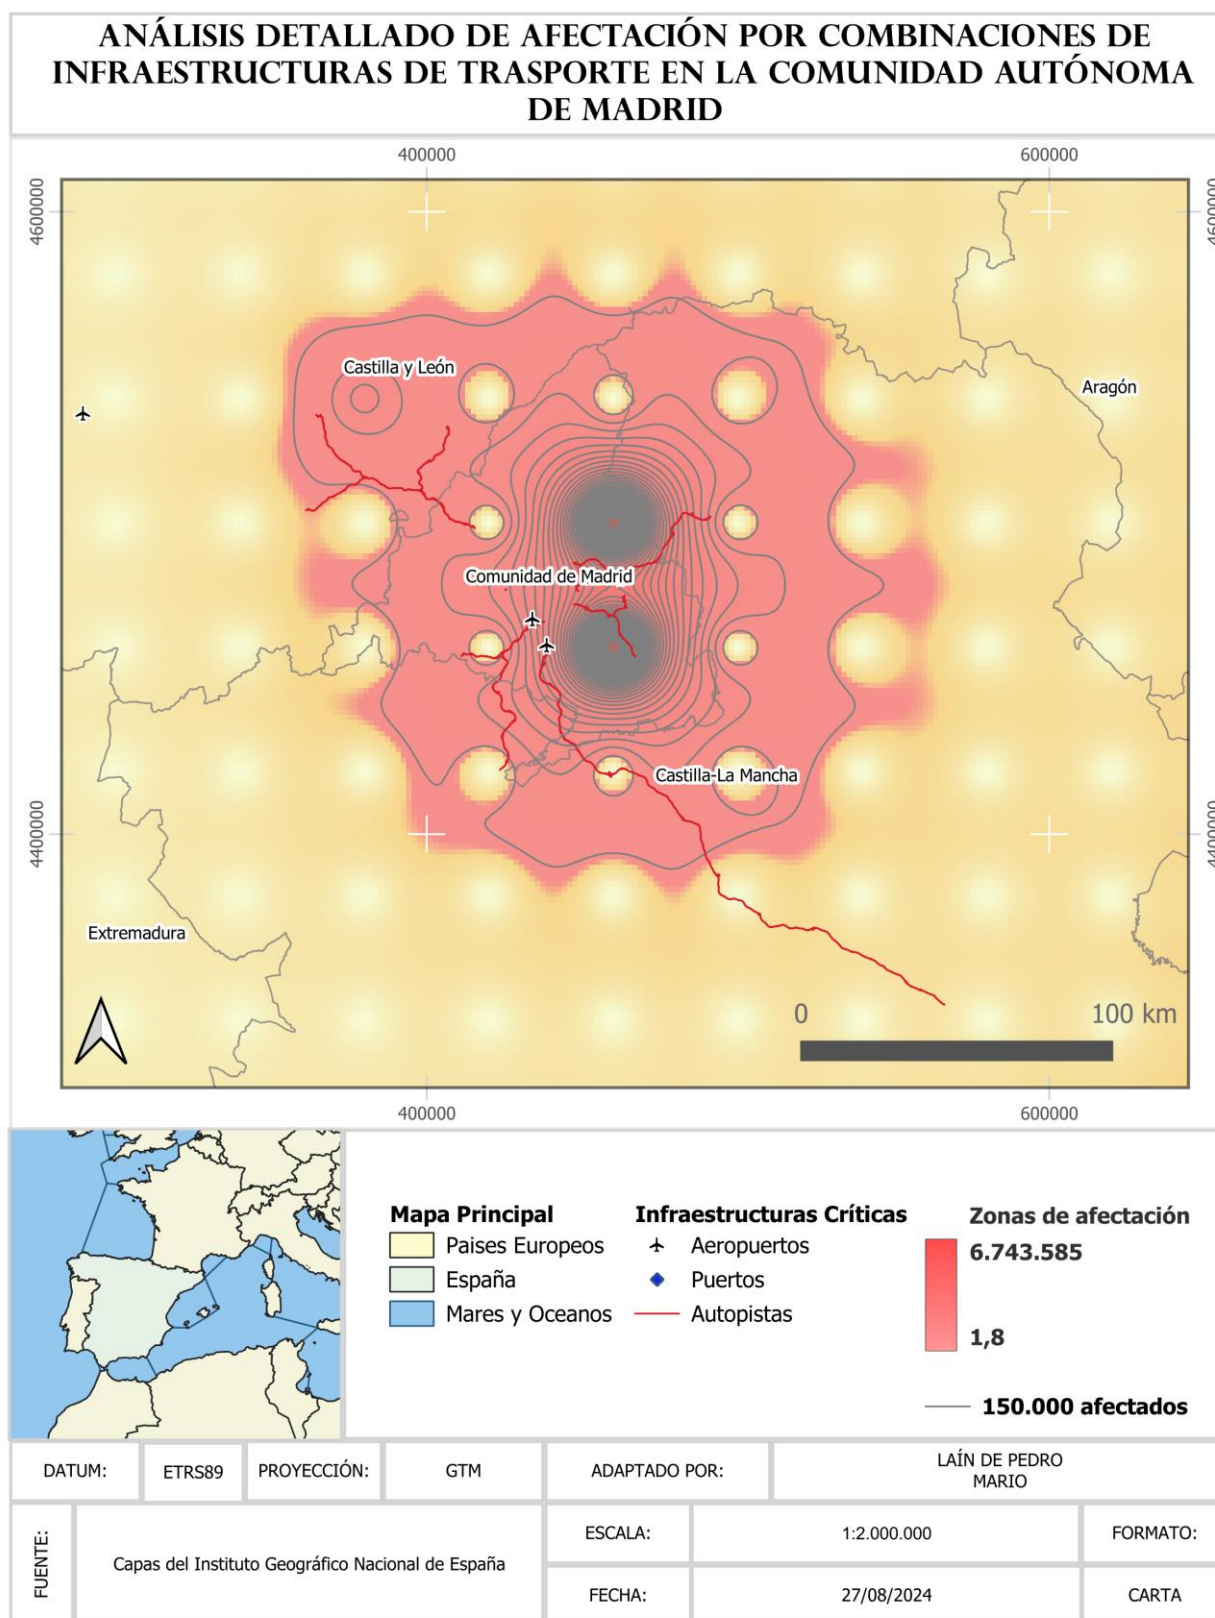


Figura 155. Análisis detallado de afectación por combinaciones de infraestructuras de transporte en la Comunidad Autónoma de Madrid.

Otra de las zonas de interés a proteger sería toda la costa norte de España (Figura 152) en especial las zonas de Galicia y el país vasco que es donde se observan niveles mayores riesgos. Esto es debido a la multitud de puertos que crean una vasta región de riesgo provocando un gran número de afectados en toda la costa pero sobre todo en las inmediaciones del Bilbao. Como se puede comprobar en las en las (figura 156) con más de 1.500.000 de afectados.

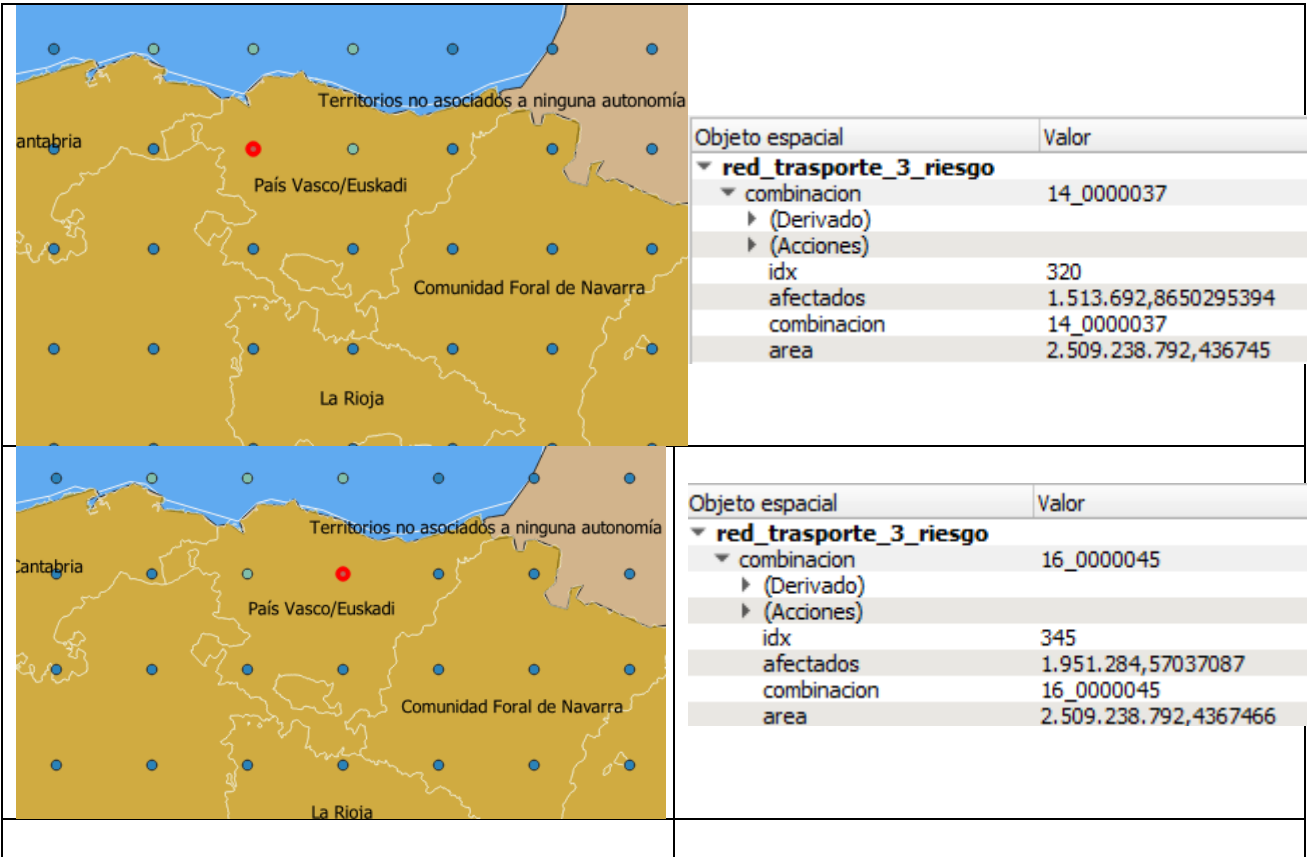


Figura 156. Número de afectados en los centroides del país vasco.

	idx	afectados	combinacion	area
1	287	6.745.595,7226...	14_0000032	2.509.238.792,4...
2	288	6.707.695,5044...	14_0000033	2.509.238.792,4...
3	566	662.274,36216222	14_0000045	2.509.238.792,4...
4	590	5.607.795,3988...	16_0000077	2.509.238.792,4...
5	591	5.431.728,8764...	16_0000077	2.509.238.792,4...
6	616	5.164.205,3021...	16_0000072	2.509.238.792,4...
7	540	2.771.648,6875...	16_0000091	2.509.238.792,4...
8	565	2.734.724,3060...	16_0000090	2.509.238.792,4...
9	460	2.604.306,8123...	16_0000014	2.509.238.792,4...
10	461	2.385.632,1875...	16_0000006	2.509.238.792,4...
11	431	2.318.888,4162...	16_0000035	2.509.238.792,4...
12	345	951.284,57037087	16_0000045	2.509.238.792,4...
13	457	1.949.569,1571...	16_0000031	2.509.238.792,4...
14	346	1.934.598,0589...	16_0000045	2.509.238.792,4...
15	129	1.783.671,6556...	14_0000068	2.509.238.792,4...

Tabla 15. Los 15 registros con mayor número de afectados en el ataque a los trasportes.

6.2. Regiones españolas de máximo riesgo de afectados por ataque de combinaciones en infraestructuras críticas universitarias y militares.

Otro caso de estudio interesante fueron las combinaciones entre diferentes elementos de las infraestructuras críticas de defensa (zonas militares) y los elementos de las zonas universitarias. Estas combinaciones son interesantes debido que las universidades y las zonas militares son zonas donde se concentran la mayoría de la población más joven del país y cualquier ataque terrorista o de agresión a estas infraestructuras podría terminar con muchos jóvenes muertos cosa que traería graves consecuencias para nuestra economía.

Consecuentemente el primer aspecto a resaltar será visualizar la (figura 157) para hacernos una idea a grandes rasgos de cómo se distribuyen ambas infraestructuras críticas por el territorio español. En primer lugar se puede comprobar en el mapa como las universidades están repartidas homogéneamente por todo el territorio español. Cada Comunidad Autónoma tiene varias incluso se podría llegar a decir que prácticamente todas las provincias tienen una en las distintas capitales de sus territorios. El segundo aspecto a tratar es como las zonas militares tienen una distribución irregular por el territorio, esto tiene que ver con estrategias de defensa del territorio y con la geopolítica porque hay zonas que por orografía son más adecuadas para asentamientos militares. Pero se puede apreciar como hay gran cantidad de ellas en Madrid, Aragón, Comunidad Valenciana, y se acentúa su número en Andalucía y Ceuta y Melilla. Este aumento del número de bases militares en estas regiones debe a factores estratégicos, históricos y geopolíticos. En el caso de Andalucía su posición geoestratégica dentro de España y del mundo cercano al estrecho de Gibraltar, lo convierte en un punto estratégico para el control del acceso al Mediterráneo y la conexión con África del Norte. El estrecho es una de las rutas marítimas más transitadas del mundo, lo que hace que su control sea vital para la seguridad nacional y la defensa del territorio Europeo. Además Andalucía ha tenido históricamente una fuerte presencia militar debido a su proximidad con los antiguos reinos moros y su papel en las guerras de la reconquista. Las bases y zonas militares en esta región han sido fundamentales para la defensa de la península a lo largo de los siglos. La cercanía de Andalucía, Ceuta y Melilla con el norte de África hace que estas regiones sean puntos críticos para la vigilancia contra el terrorismo y la gestión de la inmigración ilegal. Las tensiones en la geopolítica global además de la proximidad a zonas inestables en el norte de África y Medio Oriente, han llevado a España a fortalecer su presencia militar en estas áreas para garantizar la seguridad nacional y cumplir con sus compromisos dentro de la OTAN y la UE.



Figura 157. Distribución de los elementos de las zonas militares e universitarias en España.

En la (figura 159) se puede apreciar las regiones con mayor número de afectados por las combinaciones de elementos de universidades y zonas militares. Las áreas con mayor concentración de afectados se

localizan mayoritariamente en la Comunidad de Madrid, Cataluña, Andalucía y la Comunidad Valenciana debido a su alta densidad de población y la multitud de universidades y zonas militares que alberga. Lo más curioso de este mapa es como se extiende desde Madrid hacia Castilla y León y la Comunidad Valenciana una región gigantesca de afectados. Estos casos se ven mucho mejor en la (figura 161) donde se ha puesto zoom a estas zonas para visualizar mejor y así saber que infraestructuras son las que afectan y además poder ver las curvas de afectados. Se puede observar con mayor precisión (Figura que la zona del levante español Valencia y Murcia están ocupadas por multitud de zonas militares y alguna que otra universidad. Otro aspecto a destacar sería que la zona del levante está muy densamente poblada y si no acercamos a las curvas de nivel se pueden ver claramente multitud de curvas de nivel todas ellas muy juntas como en el caso de Madrid y Barcelona (Figuras 161, 162) que indican que en esa región el de afectados se dispara.

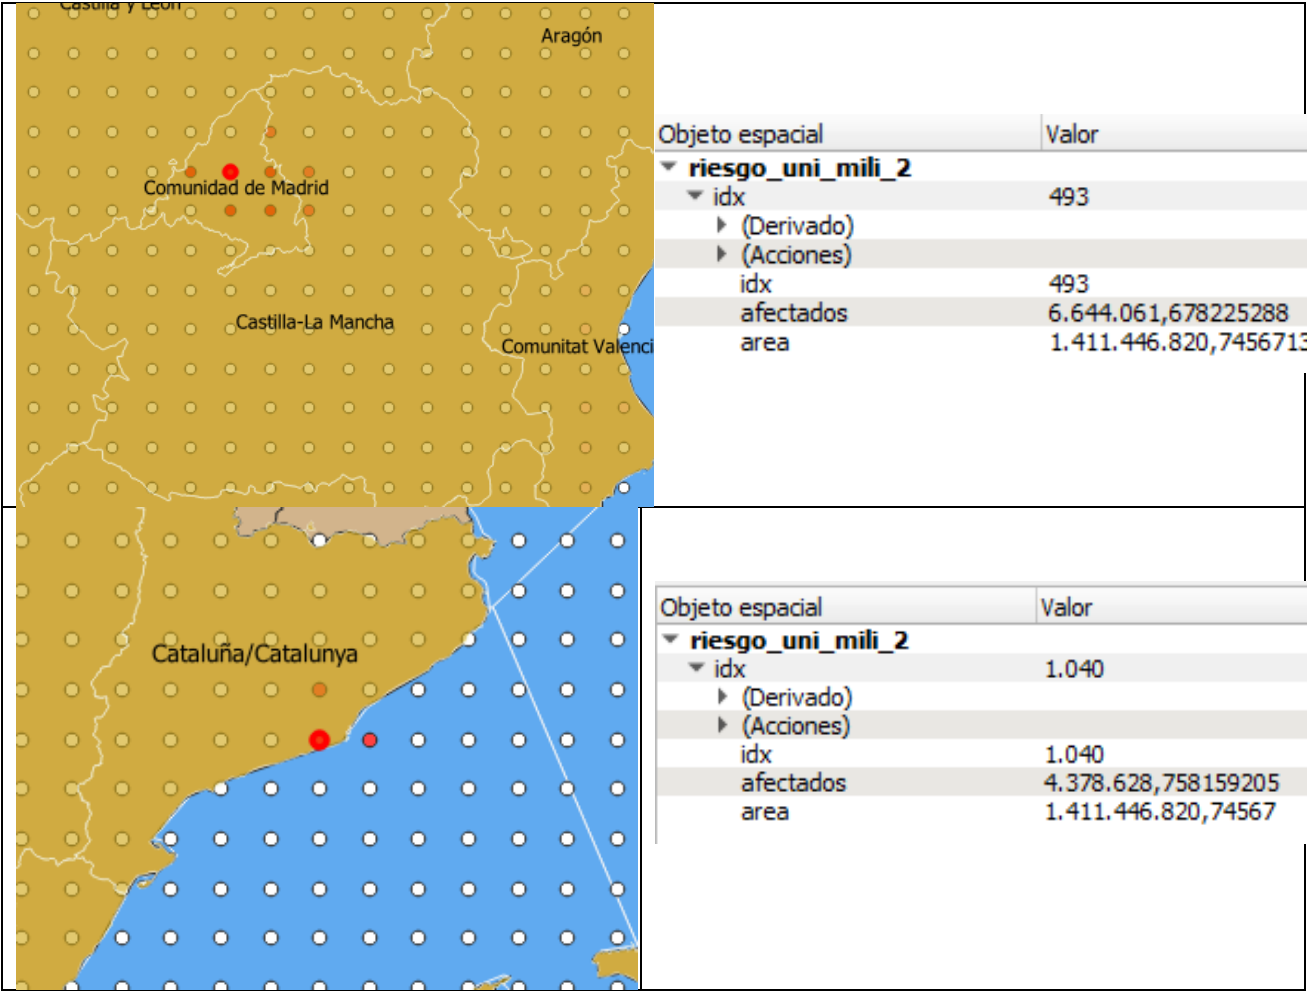


Figura 158. Centroides de mayor número de afectados en la Comunidad de Madrid y la Comunidad Autónoma de Cataluña.

Se aprecia en la (figura 158) como en los centroides centrales de nuestra grilla en Madrid los casos vuelven a superar los seis millones de afectados, números que asustan de las posibles consecuencias

adversas que podrían darse en la capital. El caso de Cataluña no es nada halagüeño tampoco ya que el número de afectados supera los cuatro millones en la capital y sus cercanías estos números desorbitados son debidas a las grandes acumulaciones de personas dentro de las grandes urbes de España además de la multitud de universidades y zonas militares dispersas por esta parte del territorio. (Figura 162) Barcelona y Madrid se convierten en las regiones más vulnerables a estas combinaciones de ataques. La capital siendo un centro administrativo y educativo amplificaría las repercusiones. Por lo tanto estas regiones necesitan una respuesta rápida y coordinada de los servicios de seguridad y emergencias. Los ataques a universidades provocarían una interrupción en la educación y afectaría a miles de estudiantes y personal académico, creando un ambiente de inseguridad. Los ataques a zonas militares no solo afectarían a las infraestructuras de defensa sino también a la moral y seguridad nacional.

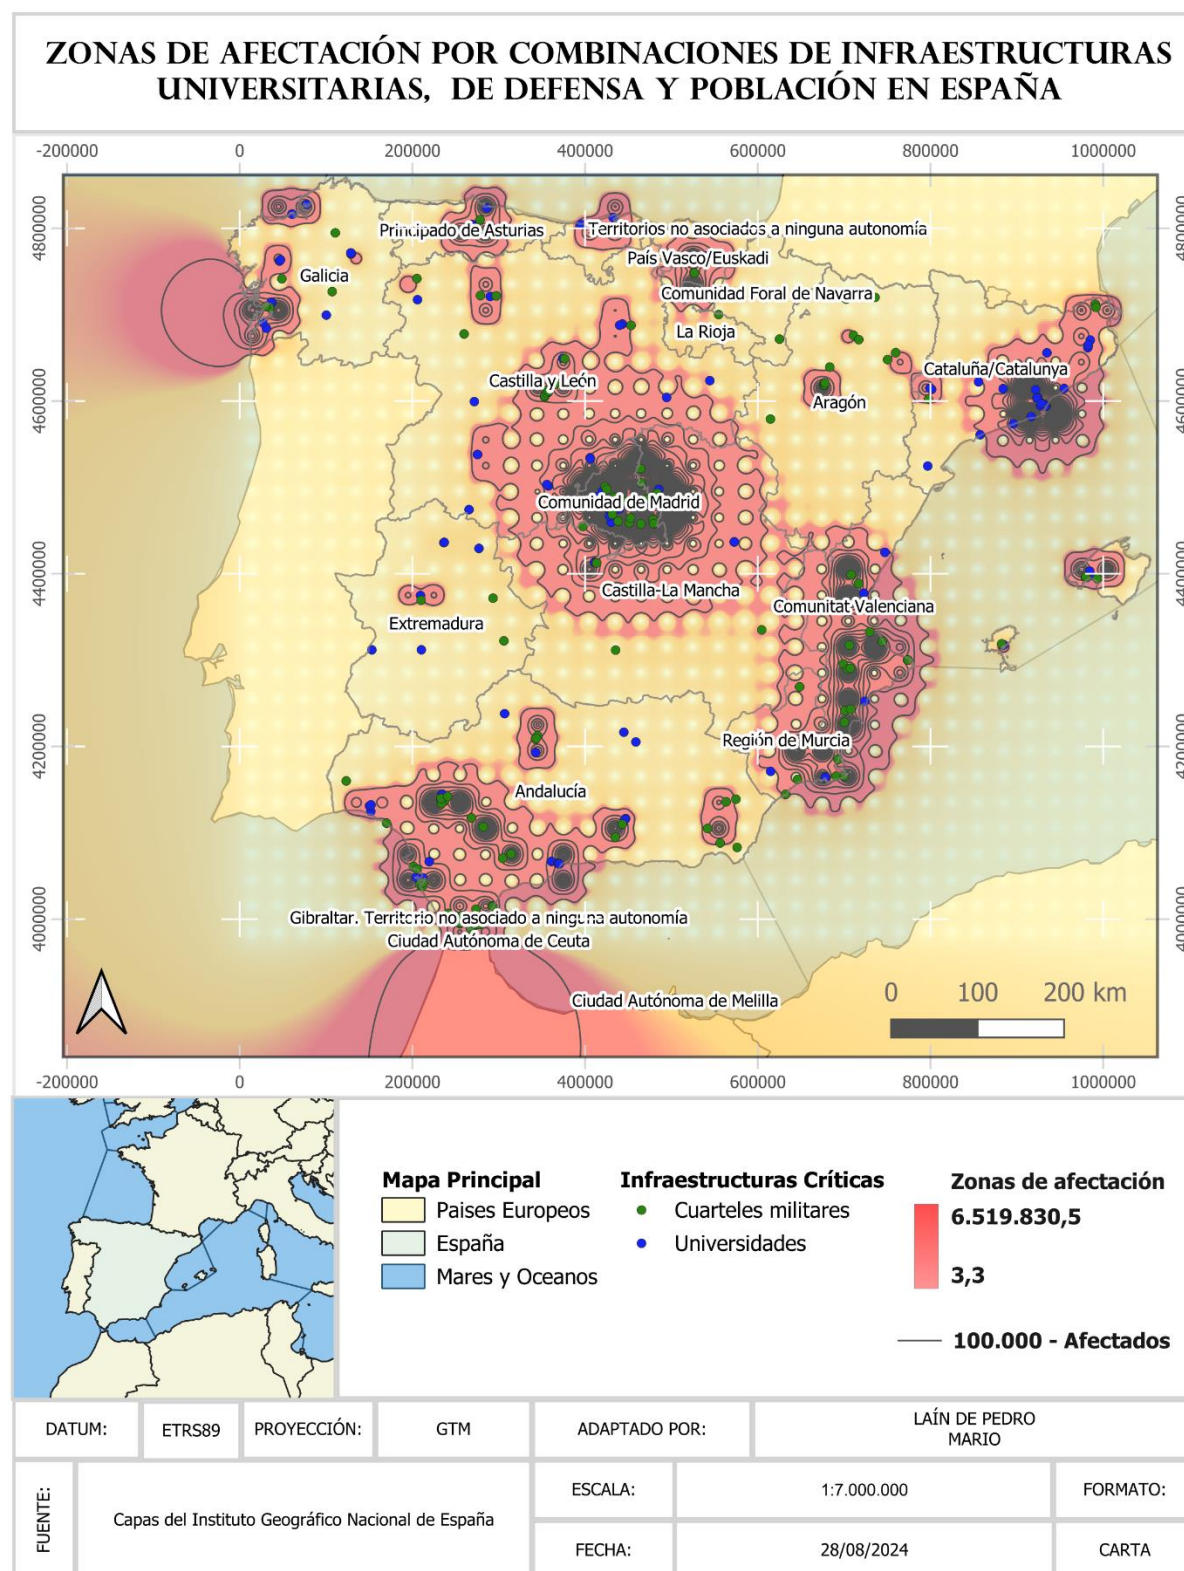


Figura 159. Zonas de afectación por combinaciones de infraestructuras universitarias de defensa y población en España.

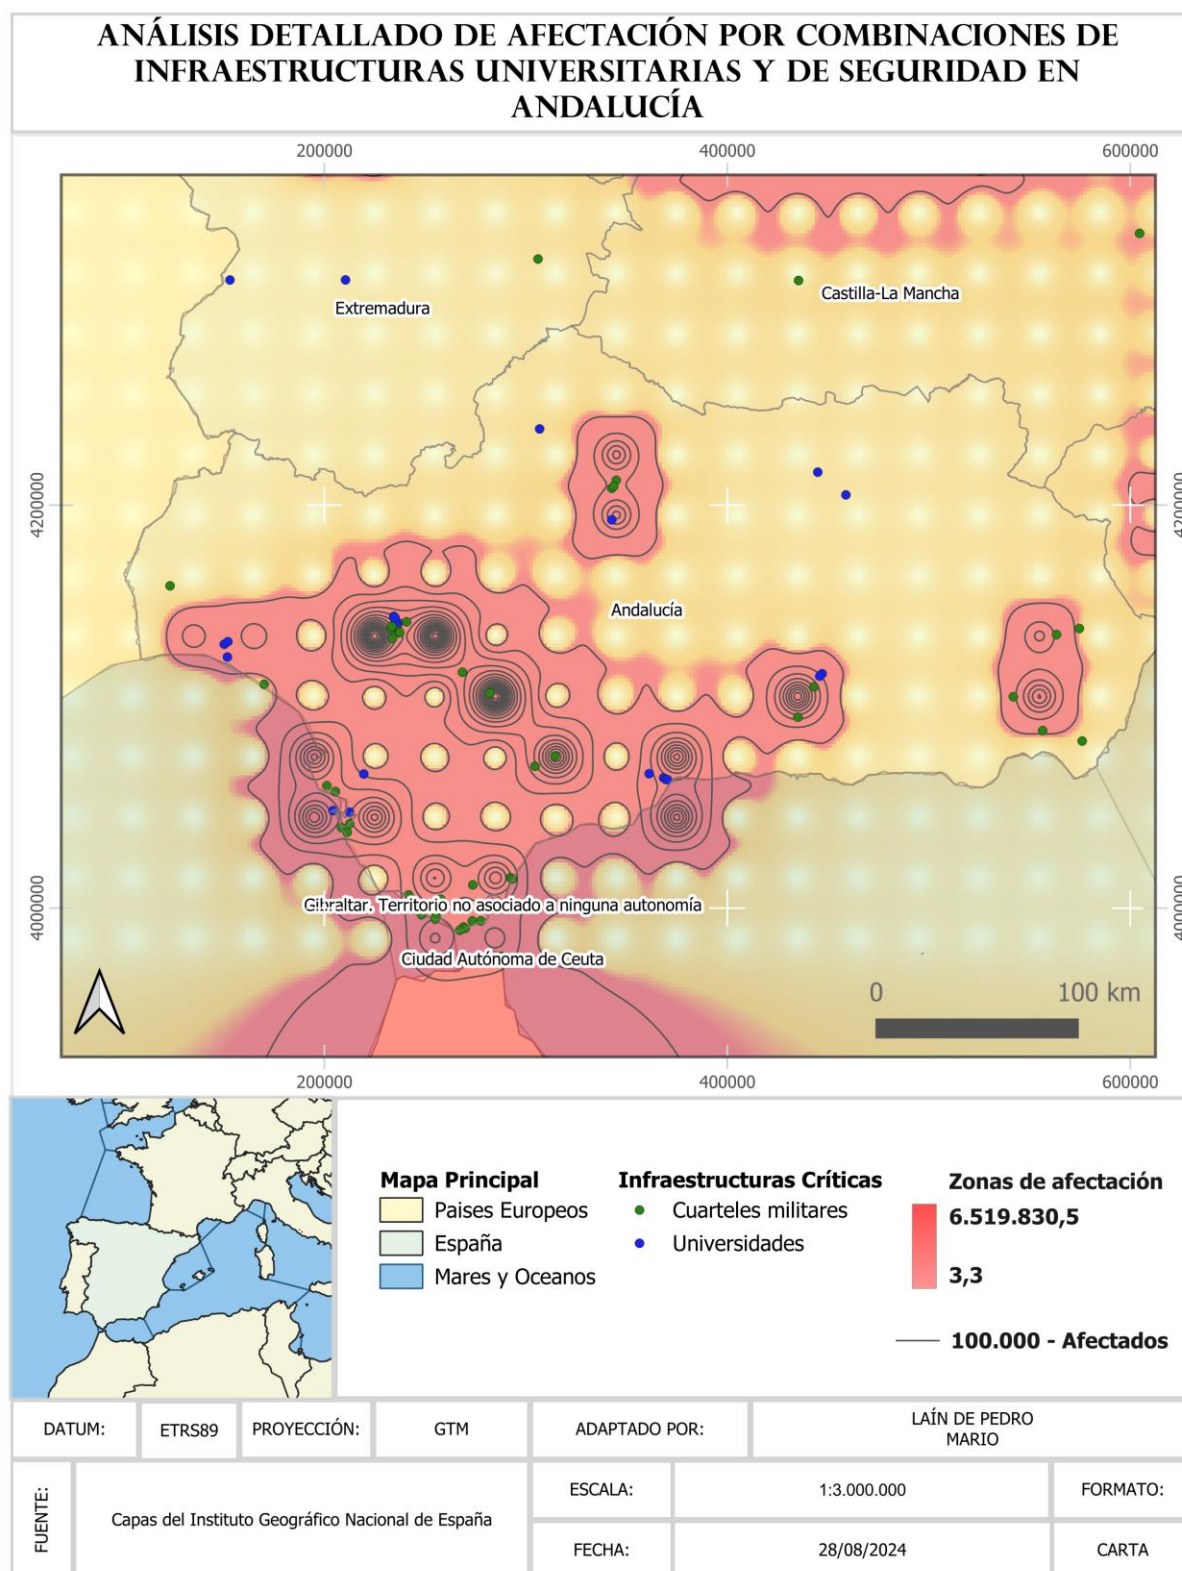


Figura 160. Zonas de afectación por combinaciones de infraestructuras universitarias, defensa y población en Andalucía.

Algunas deducciones regionales como el caso de Andalucía muestra una alta concentración de afectados en Sevilla, Málaga y Cádiz, indicando que estas ciudades tienen tanto una fuerte presencia universitaria como militar. Los ataques en estas áreas afectarían a una gran parte de la población de la región.

Mapa Principal

- Países Europeos
- España
- Mares y Océanos

Infraestructuras Críticas

- Cuarteles militares
- Universidades

Zonas de afectación

6.519.830,5

3,3

100.000 - Afectados

DATUM: ETRS89 **PROYECCIÓN:** GTM **ADAPTADO POR:** LAÍN DE PEDRO MARIO

ESCALA: 1:2.500.000 **FORMATO:** CARTA

FECHA: 28/08/2024

FUENTE: Capas del Instituto Geográfico Nacional de España

150

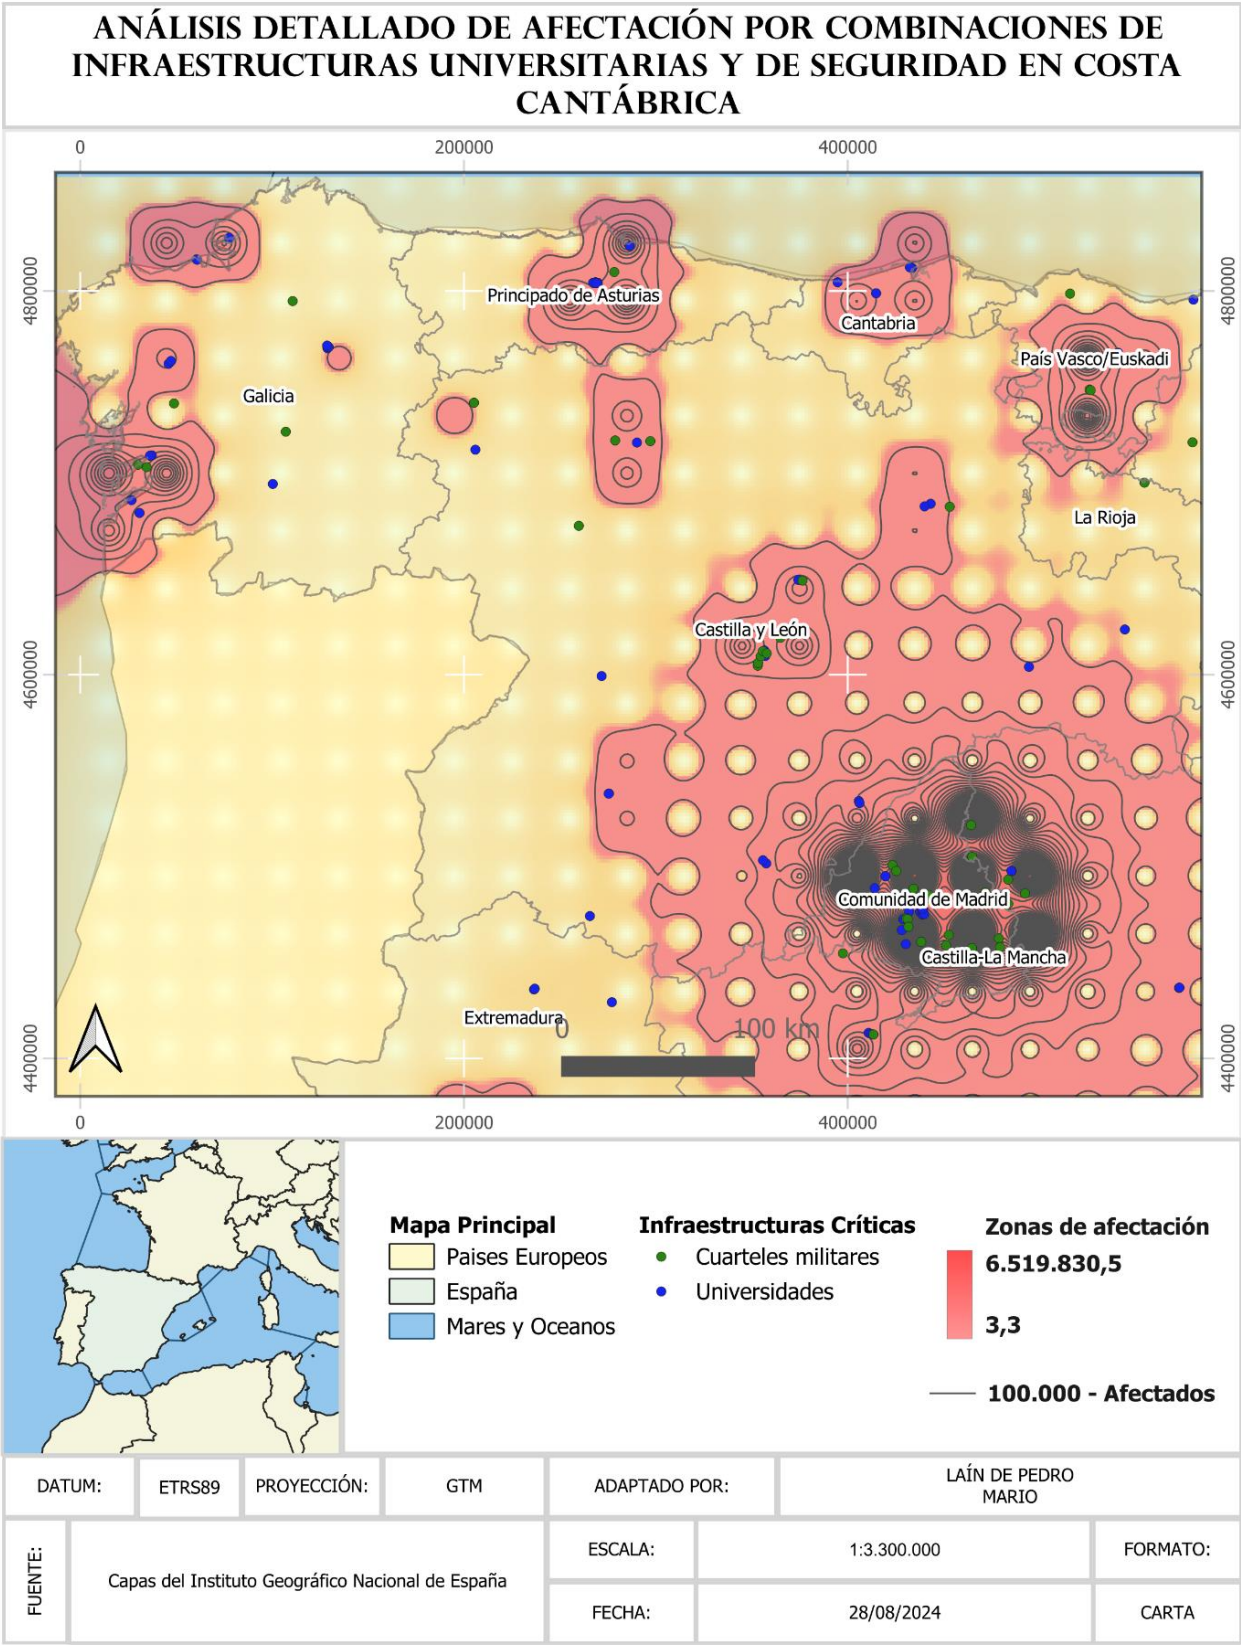


Figura 163. Análisis detallado de afectación por combinaciones de infraestructuras universitarias de defensa y población en la costa Cantábrica.

6.3. Regiones de máximo riesgo de personas afectadas por ataque a la producción eléctrica de las renovables.

La (figura 164) muestra la distribución de la localización de las infraestructuras críticas de producción de energía renovable en España (se incluyen dentro de este caso de estudio centrales eólicas, solares e hidroeléctricas). La localización de las infraestructuras de energías renovables está directamente influenciada por las condiciones climáticas y geográficas que maximizan la eficiencia y producción de energía. Las centrales eólicas predominan en la mitad norte del país, con una alta concentración de ellas en Galicia, Castilla y León y Aragón. Estas regiones tienen condiciones favorables de viento debido a la influencia de sistemas meteorológicos y corrientes de aire. Galicia, por ejemplo, recibe vientos atlánticos fuertes y constantes que provienen de los océanos. En los casos de Castilla y León y Aragón crean corrientes de viento aceleradas, ideales para la generación eólica. El caso de Aragón es muy conocido ya que tiene un viento muy característico de la región llamado Cierzo y es uno de los factores que hacen de Aragón una región propicia para la instalación de molinos de viento. La constancia y la fuerza del cierzo propician condiciones óptimas para la generación de energía eólica.

Por contrapartida las centrales de energía solar se concentran en regiones de alta insolación como Andalucía, Comunidad Valenciana y Región de Murcia (Figura 164) debido a que estas áreas se encuentran entre las regiones con mayor cantidad de horas de sol al año en Europa. Andalucía por poner un ejemplo tiene una media de 2.800 horas de sol. Estas regiones reciben mayores niveles de radiación solar debido a su proximidad al ecuador y las condiciones meteorológicas que permiten cielos despejados durante la mayor parte del año. Por contra partida las plantas de energía hidroeléctrica por otro lado se sitúan en el norte de España sobre todo en Galicia, Castilla y León los pirineos, sobre todo el catalán y el vasco. Estas regiones tienen altos niveles de pluviosidad y números ríos y embalses, lo que lo convierten en lugares ideales para la generación hidroeléctrica. La orografía montañosa del norte de España propicia la construcción de presas y embalses necesarios para la generación de energía eléctrica.

En la (figura 165) se visualizan perfectamente las regiones de máximo riesgo por número de afectados a un ataque a las infraestructuras de energías renovables y son la gran mayoría de las zonas que se ha estado hablando en párrafos anteriores. La práctica totalidad del norte de España se visualiza como zona crítica con un riesgo elevado de afectados, este aspecto nos habla de la relevancia que tiene el norte de la península en la producción de energía limpia (Figura 166). Esto se debe en gran medida a la gran acumulación de centrales hidroeléctricas en esta área de España además de algunas eólicas sobre todo en la zona de Galicia. Esta gran región del norte se debe de proteger con mayor ahínco debido a que es la suministradora principal de energía limpia hacia toda España. Los mapas (Figura 166, 167, 168) con los distintos zooms a las zonas norte y sur de España donde se concentran el mayor

riesgo de afectados debido a su alta acumulación de infraestructuras de producción de energía limpia además de porque en estas zonas se acumulan grandes cantidades de población que provocarían falta de suministro energético a una gran masa de población si ocurriera algún inconveniente en ellas, con el consecuente parón en todos los demás sectores por la falta de energía. En el caso de estudio del zoom de la región norte (Figura 166, 168), las curvas de afectados están muy juntas lo que indica un gran número de personas afectadas en País Vasco, la zona de Bilbao sobretodo ya que está muy poblada y todos las ciudades de sus alrededores. Las ciudades como Santander, Gijón, Oviedo sufrirían también de un gran número de afectados por la caída de los servicios de estas infraestructuras importantísimas para el normal funcionamiento del sistema creado a su alrededor. En Galicia regiones como la de Vigo, la Coruña, Santiago de Compostela muy pobladas y además con industrias muy demandantes de esta energía sufrirán grandes números de afectados por el corte del suministro eléctrico.

La comunidad Autónoma de Cataluña sufriría consecuencias catastrófica en el número de afectados por el parón de estas generadoras de energía limpia como se observa en (Figura 168) debido a la gran acumulación de centrales hidroeléctricas y eólicas en la propia comunidad. Además unido a las grandes acumulaciones de población que presenta en la zona costera se aprecian perfectamente en las curvas de afectados el terrible impacto que tendría en estas zonas que están densamente pobladas y son muy demandantes de energía por su modelo económico centrado en el turismo y la industria. Por otro lado se apreciar el caso particular de la ciudad de Lérida y sus alrededores donde hay una acumulación de centrales hidroeléctricas eólicas y solares en esta zona que provocan que los niveles de afectados suban en las zonas donde se acumula la mayoría de población como en Lérida ciudad y sus zona de influencia.

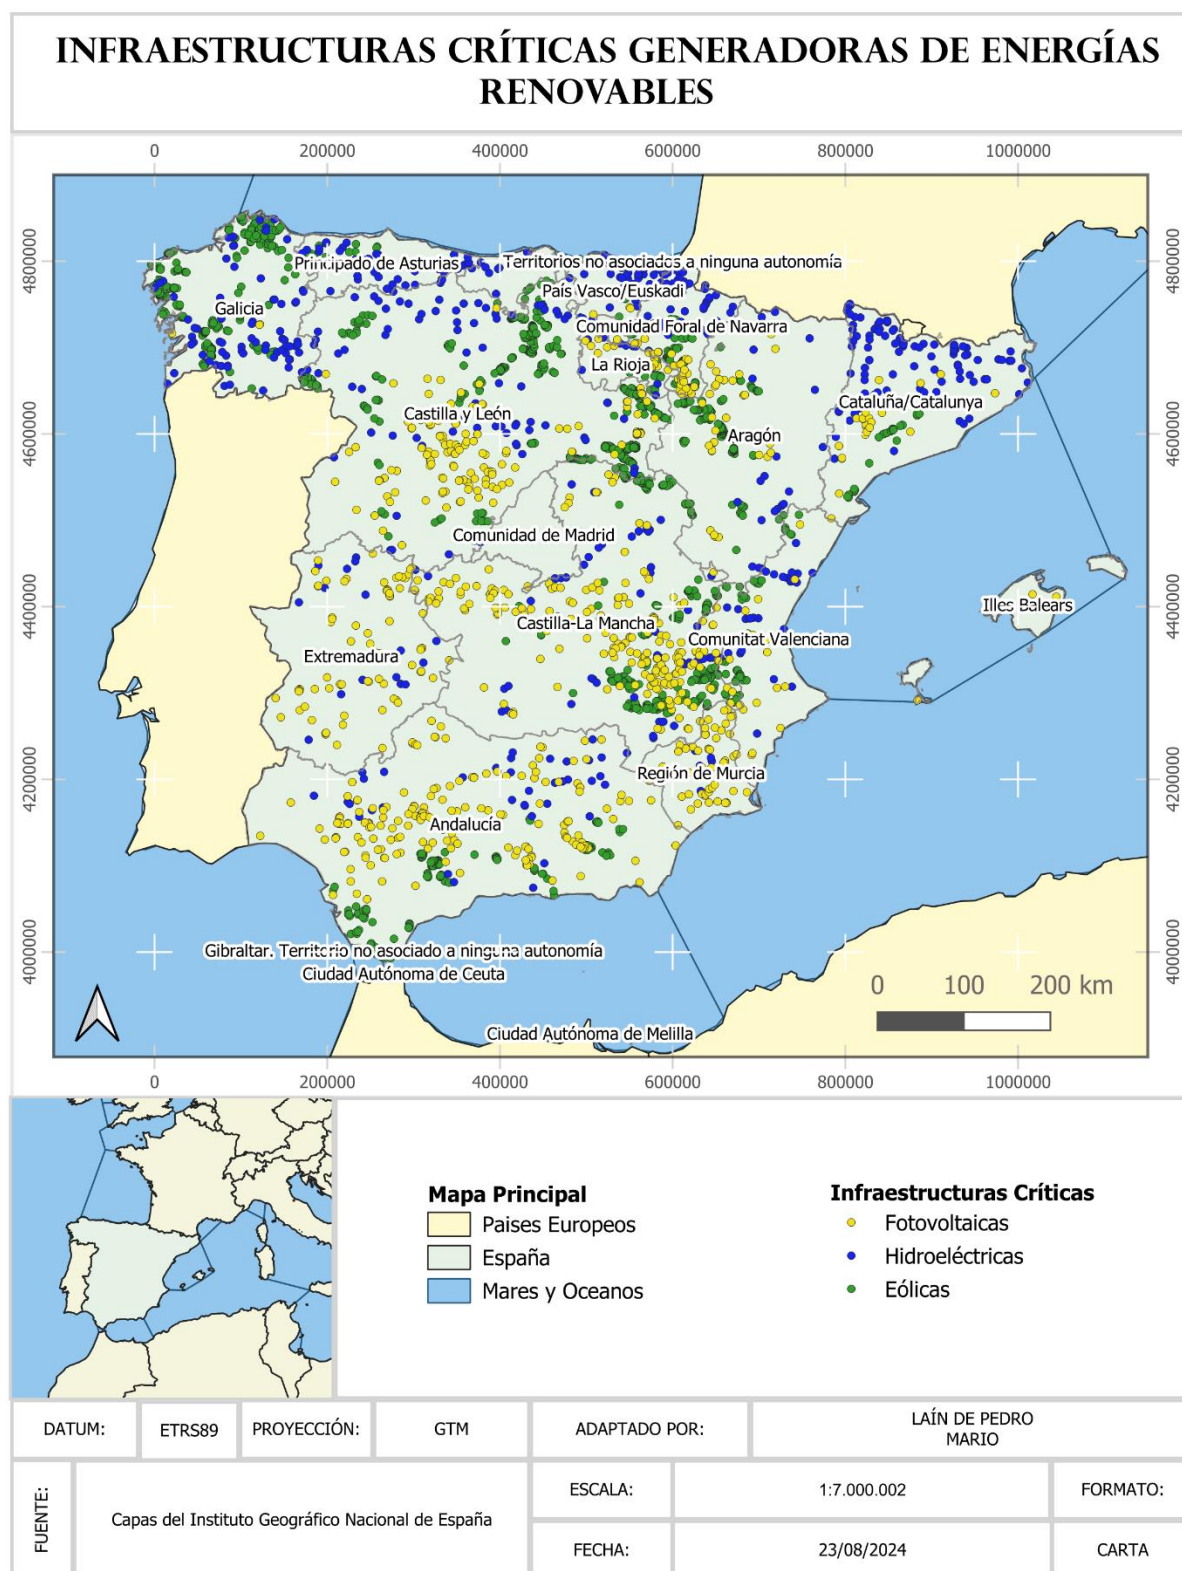


Figura 164. Distribución de los elementos de las infraestructuras de energías renovables.

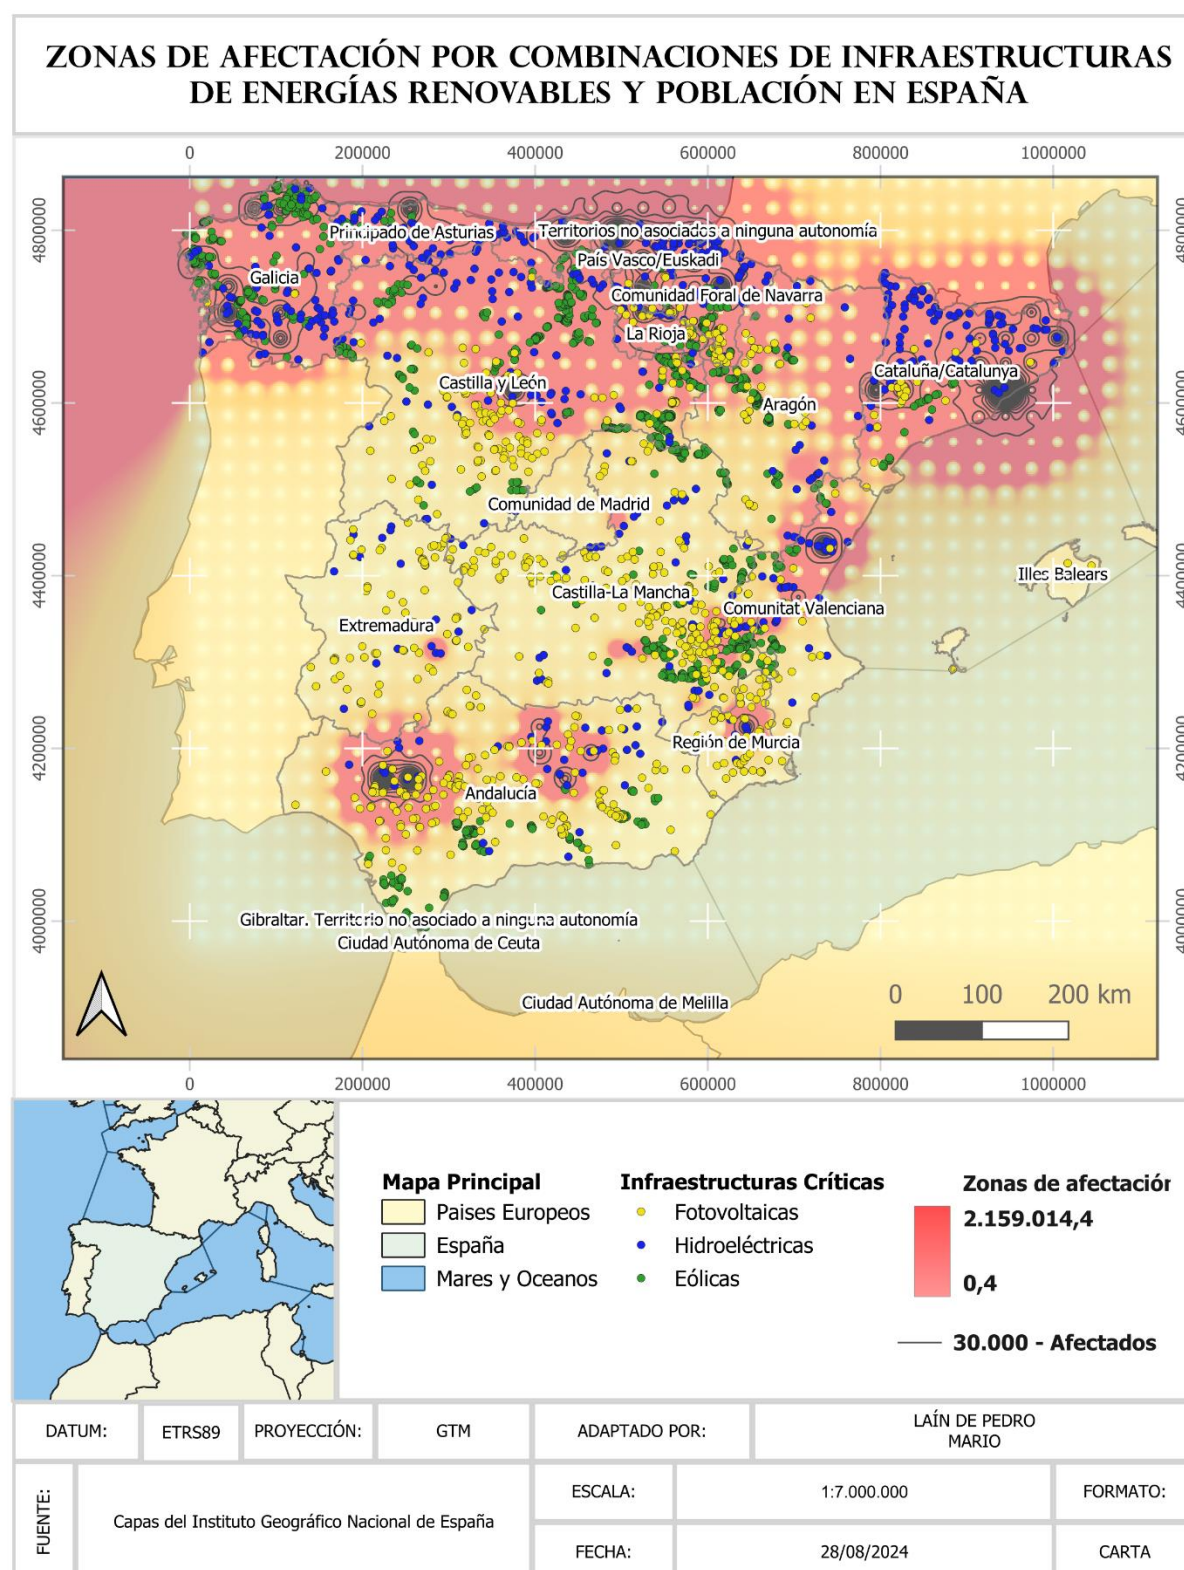


Figura 165. Zonas de afectación por combinaciones de infraestructuras de energías renovables y población en España.

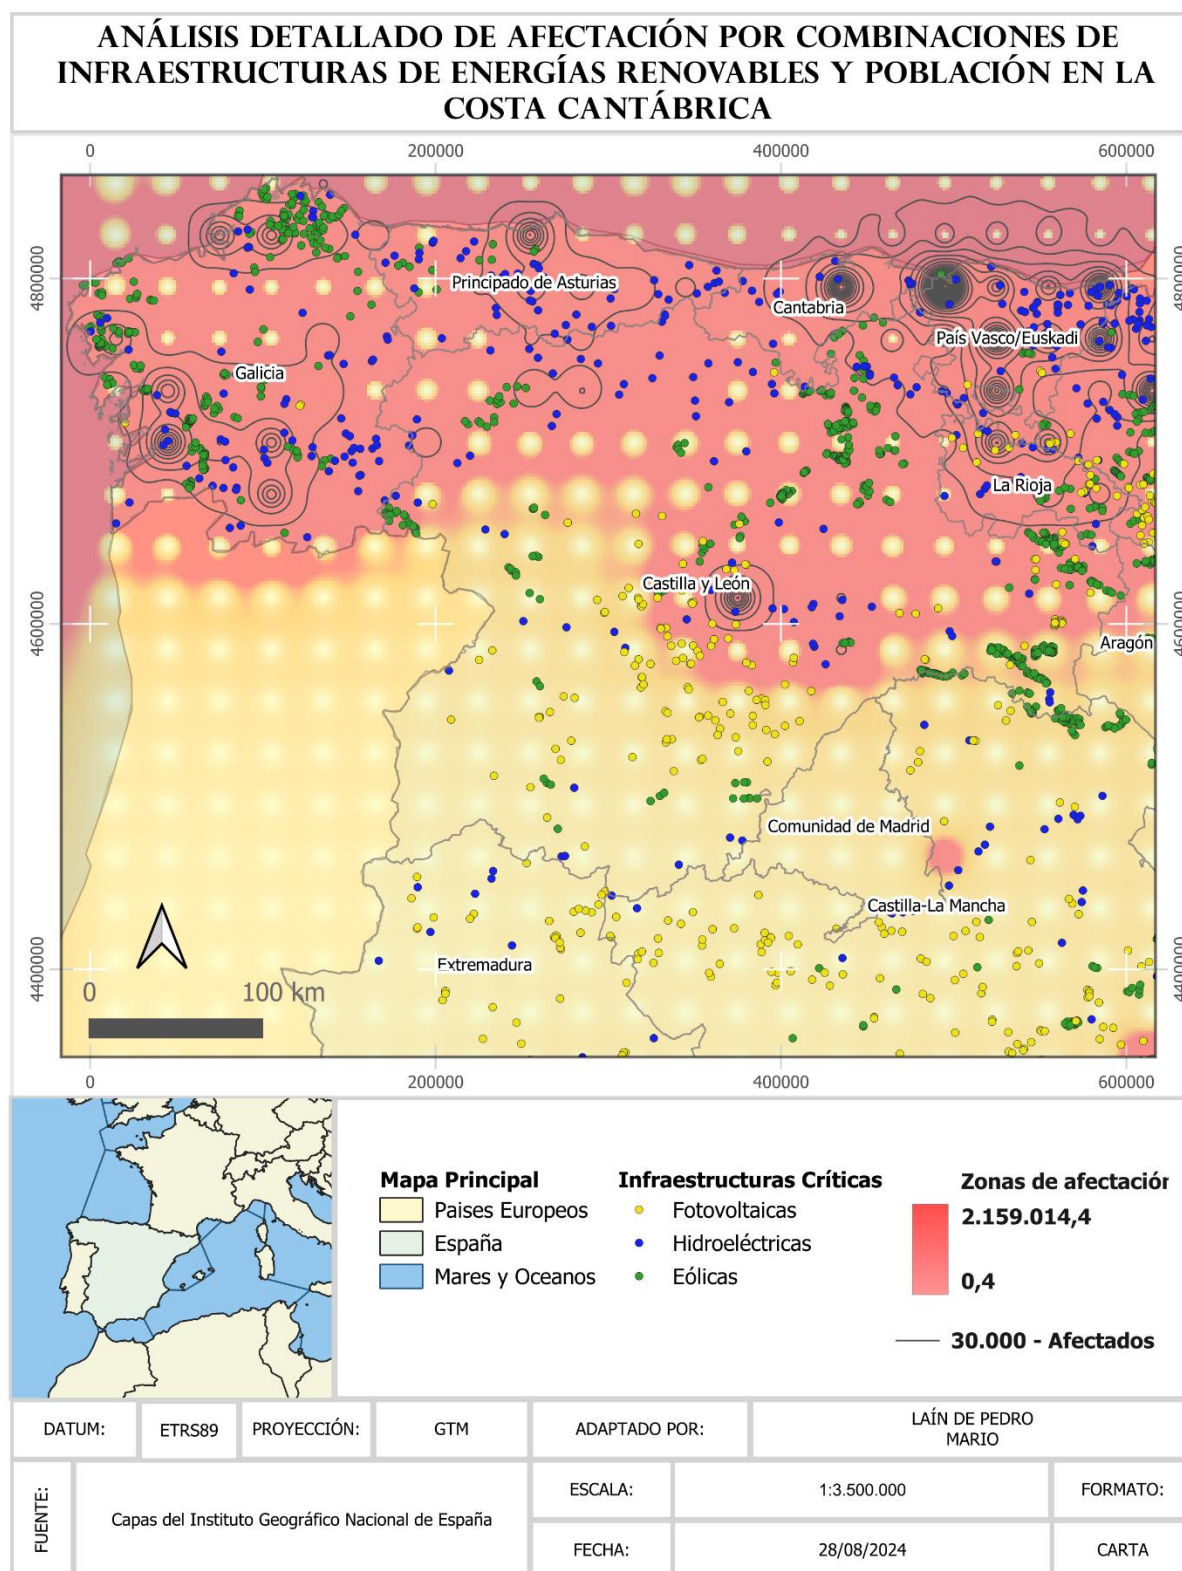


Figura 166. Análisis detallado de afectación por combinaciones de infraestructuras de energías renovables y población en la costa Cantábrica.

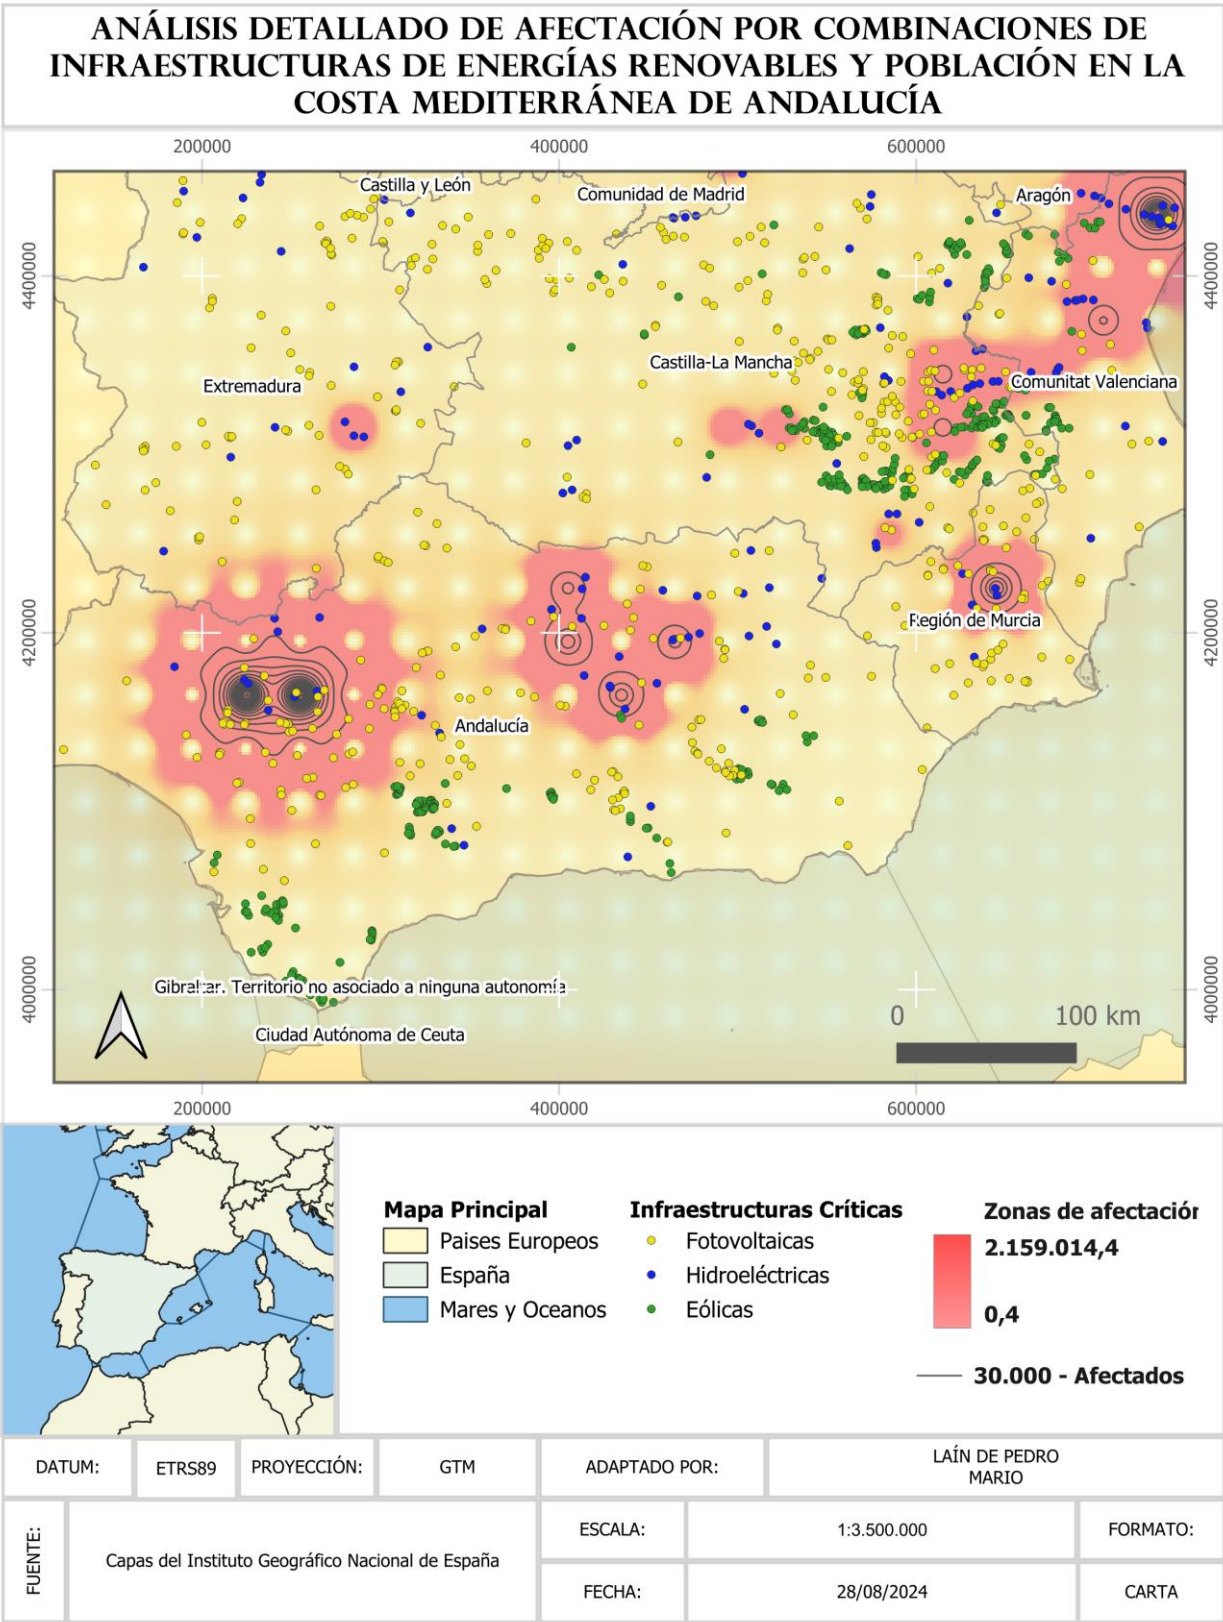


Figura 167. Análisis detallado de afectación por combinaciones de infraestructuras de energías renovables y población en la costa Mediterránea de Andalucía.

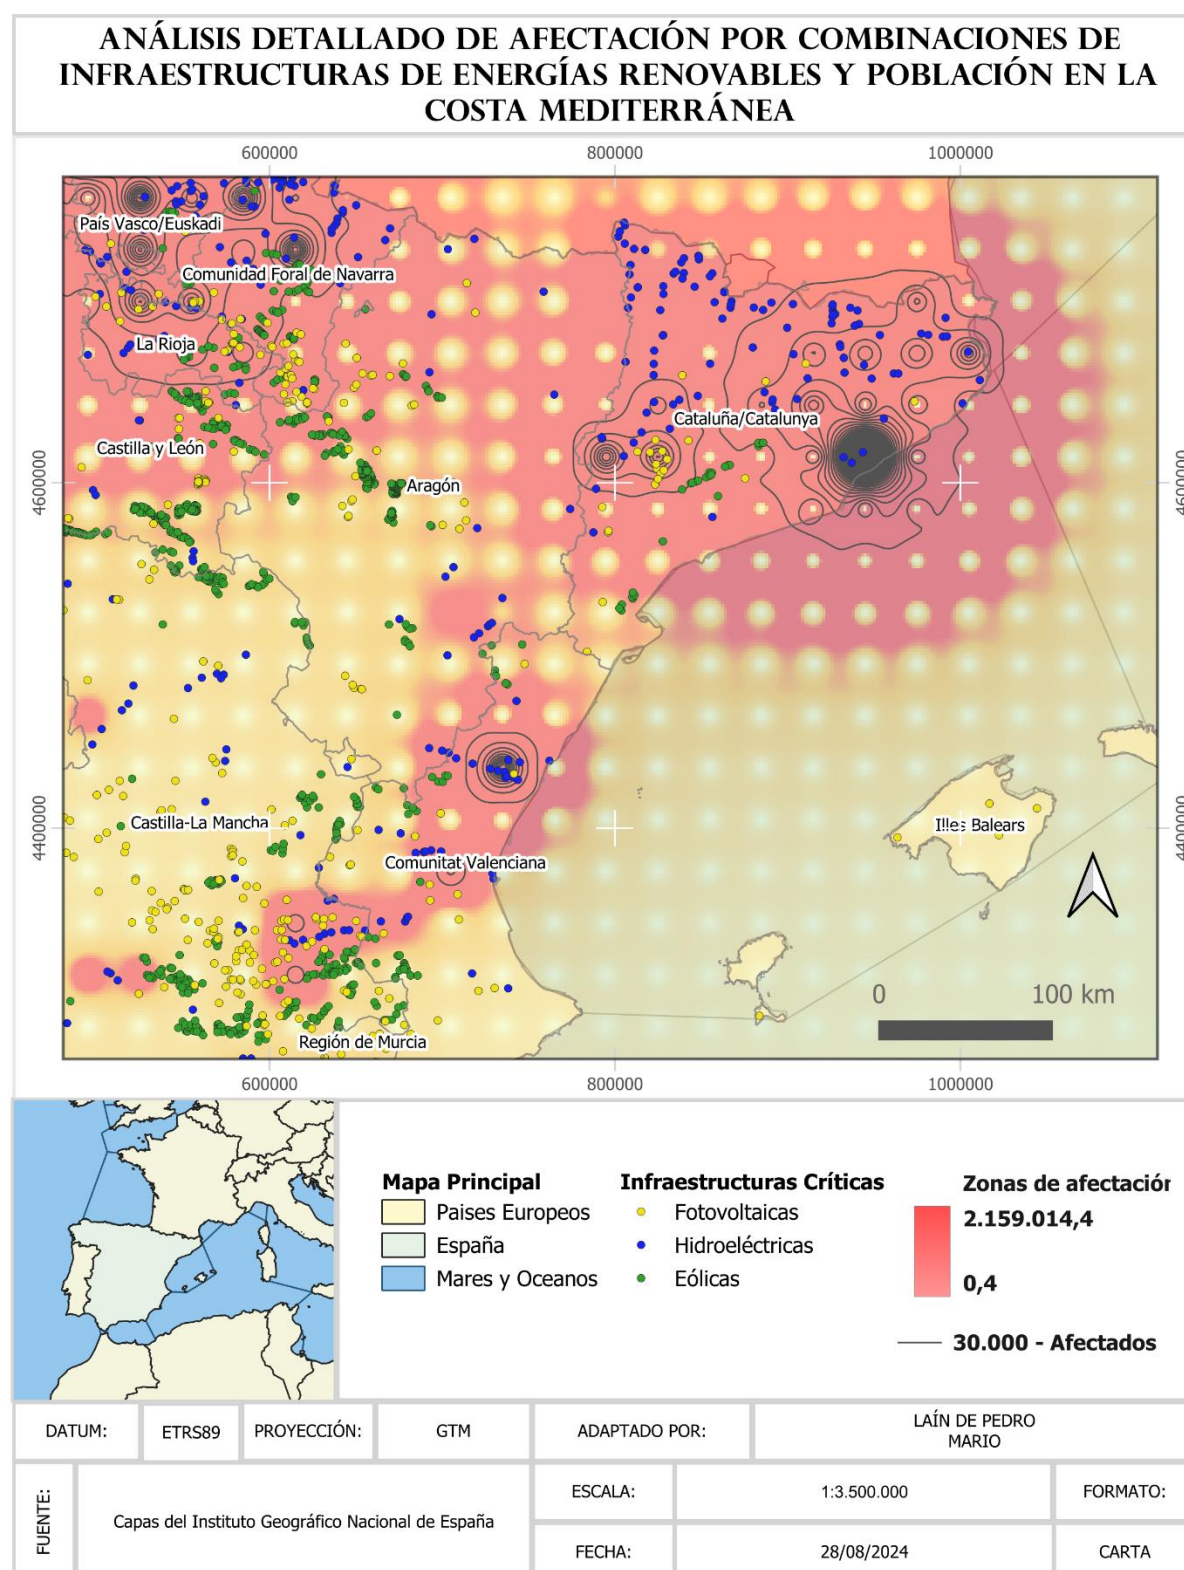
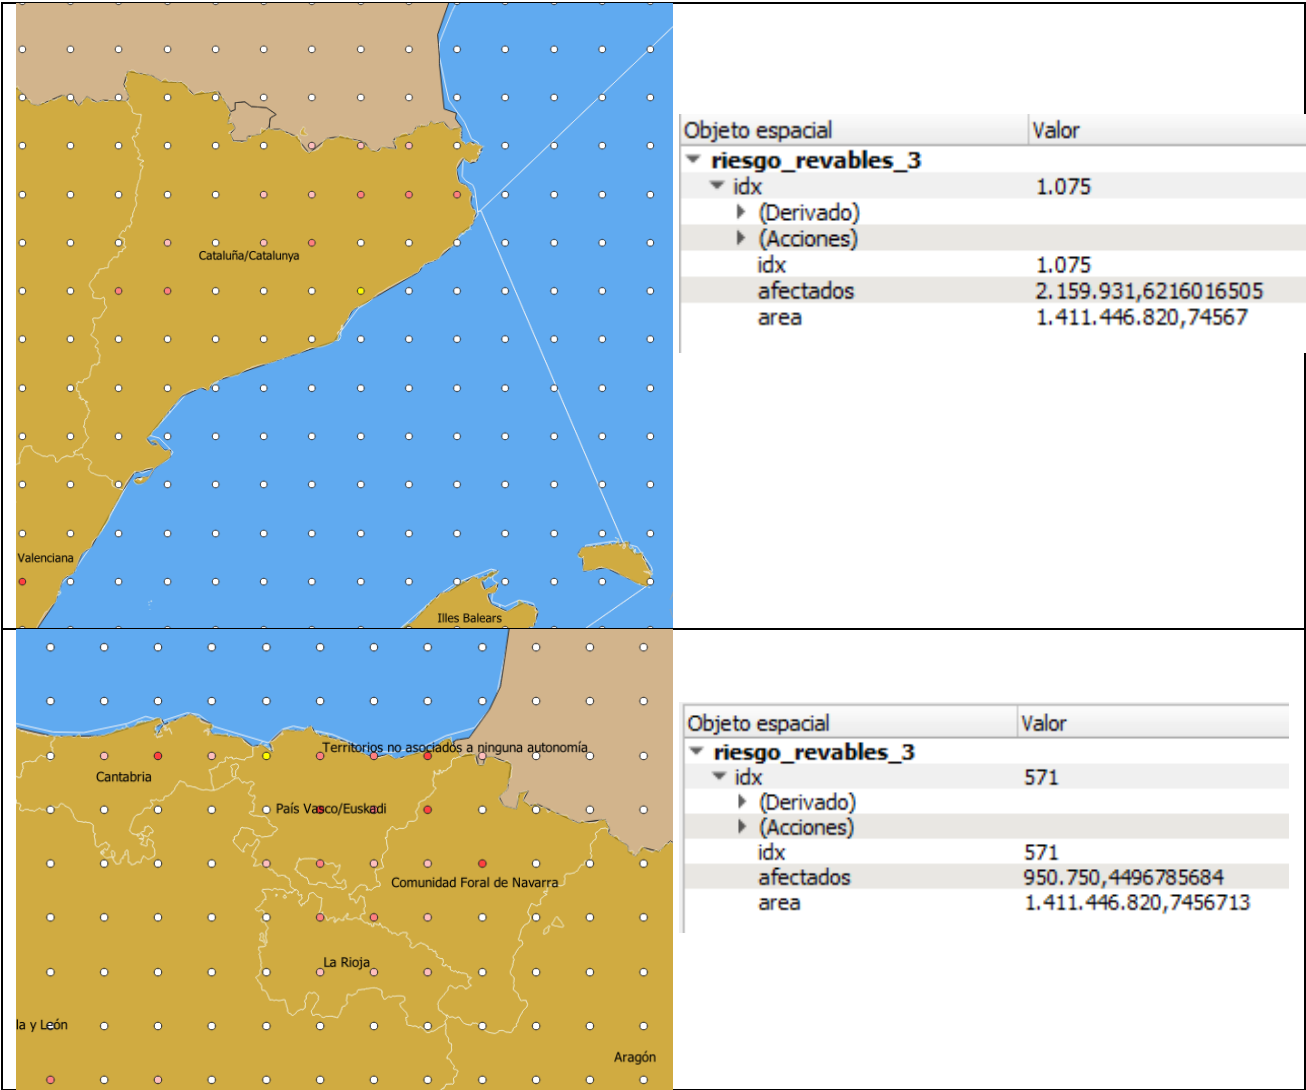
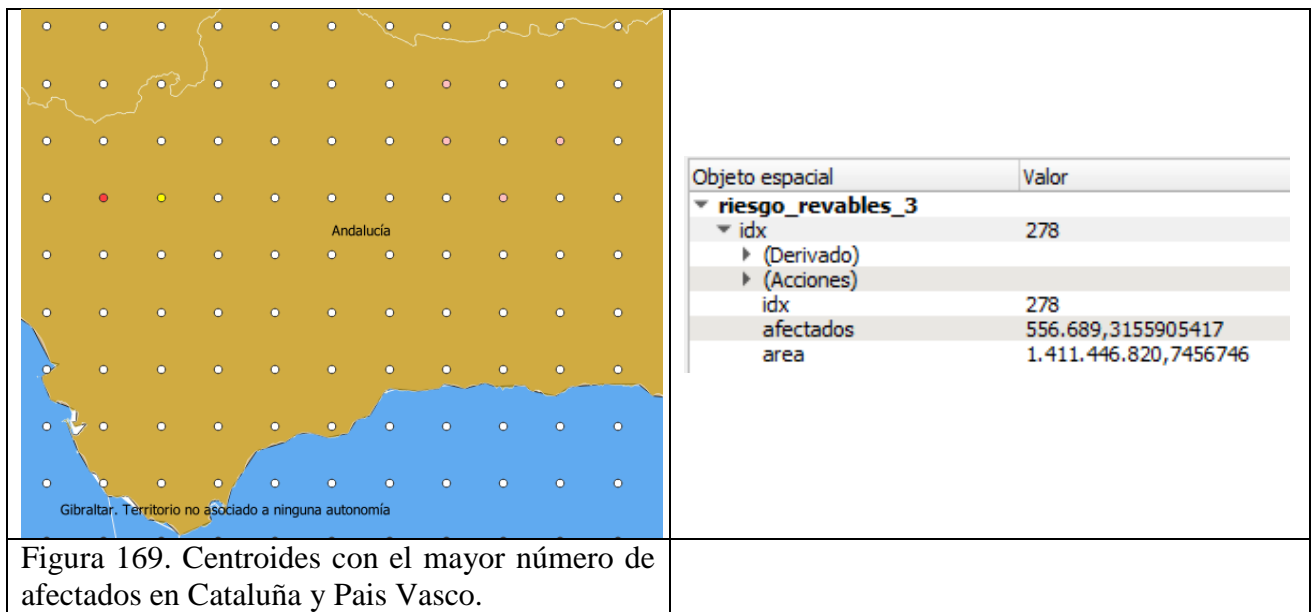


Figura 168. Análisis detallado de afectación por combinaciones de infraestructuras de energías renovables y población en la costa Mediterránea.

Se refuerza el análisis con más datos mediante la (figura 169) donde se muestran los centroides de nuestra grilla con mayor número de afectados en Cataluña y País Vasco. Muestran localizaciones de nuestros resultados finales del csv en este caso del riesgo con puntos graduados en rojos por intensidad para validar las zonas de mayor número de afectados en Cataluña y País Vasco. En la primera figura se muestro el valor más alto de afectados en nuestro análisis sobre el ataque a las infraestructuras eléctricas renovables que son más de dos millones. Y en las siguientes figuras se muestra el valor máximo de afectados en la zona del País Vasco y Andalucía. Se realizara este proceso con los tres primeros puntos donde se encuentran el mayor número de afectados por el corte de estas infraestructuras





	idx	afectados	area
1	1.075	2.159.931,6216...	1.411.446.820,7...
2	571	950.750,449678...	1.411.446.820,7...
3	278	556.689,315590...	1.411.446.820,7...
4	244	526.491,012769...	1.411.446.820,7...
5	604	431.953,954629...	1.411.446.820,7...
6	503	413.757,605924...	1.411.446.820,7...
7	831	367.266,776675...	1.411.446.820,7...
8	673	361.268,117360...	1.411.446.820,7...
9	705	352.166,270126...	1.411.446.820,7...
10	672	342.629,630712...	1.411.446.820,7...
11	603	309.927,659243...	1.411.446.820,7...
12	429	277.002,579497...	1.411.446.820,7...
13	58	273.940,364424...	1.411.446.820,7...
14	605	261.948,519777...	1.411.446.820,7...
15	602	245.156,117962...	1.411.446.820,7...

Tablas 16 Los 15 primero centroides con mayor número de afectados por ataque a las infraestructuras eléctricas.

6.4. Regiones de máximo riesgo de afectados por ataque combinado de infraestructuras críticas energéticas.

En este análisis se añadieron las centrales nucleares y térmicas para poder desarrollar un mapa de las áreas más afectadas por un hipotético ataque cibernético que dejara sin producción de luz al estado español. ¿Cuáles serían las regiones con mayor número de afectados por un parón total en la red eléctrica? Otra pregunta que surgió fue: ¿Cómo habrían cambiado estas zonas con respecto al mapa en donde solo involucramos el ataque a las renovables?

Solo se describirá la localización de las centrales nucleares y térmicas debido a que en el punto anterior se estuvo hablando de las renovables. En España, las centrales térmicas y nucleares están distribuidas de manera que su localización maximiza la eficiencia y minimiza el impacto ambiental y social en las poblaciones circundantes.

Las centrales térmicas se concentran en áreas estratégicas que facilitan el acceso a recursos y la distribución de energía. Estas centrales que pueden ser de carbón, gas o de ciclo combinado, suelen encontrarse cerca de grandes centros de consumo y en zonas costeras, lo que permite el fácil suministro de energía a zonas densamente pobladas y la evacuación de la energía generada. Algunas ubicaciones a destacar son, una gran aglomeración de centrales de carbón concentradas en el noroeste de la península (Galicia y Asturias), zonas con grande tradición de minería de carbón. Las centrales de gas y ciclo combinado están repartidas por todo el país, con una notable presencia en áreas industriales y urbanas como el Levante y el sur de Andalucía.

Las centrales nucleares en España están ubicadas en zonas relativamente aisladas para minimizar el riesgo a la población y facilitar la gestión de residuos y la seguridad. Las ubicaciones de mayor relevancia son:

Ascó (Tarragona): Con dos reactores nucleares, esta planta está situada en el noreste de España en la Comunidad Autónoma de Cataluña.

Valldellós (Tarragona): Otra central en Cataluña pero esta solo con un reactor nuclear en funcionamiento.

Almaraz (Cáceres): En el oeste de España, cuenta con dos reactores nucleares.

Cofrentes (Valencia): Localizada en el este, esta planta tiene un reactor nuclear.

Trillo (Guadalajara): En la zona central del país, cuenta con un reactor.

Santa María de Garoña (Burgos): Actualmente en proceso de desmantelamiento, se encuentra en el norte de España.

La distribución de estas infraestructuras muestra una clara adaptación a las condiciones geográficas y climáticas y orográficas como se explicó en párrafos anteriores. Como se puede comprobar en el mapa (Figura 170) hay una gran variedad de fuentes de energía, lo cual nos ayuda a la estabilidad y sostenibilidad del suministro energético.

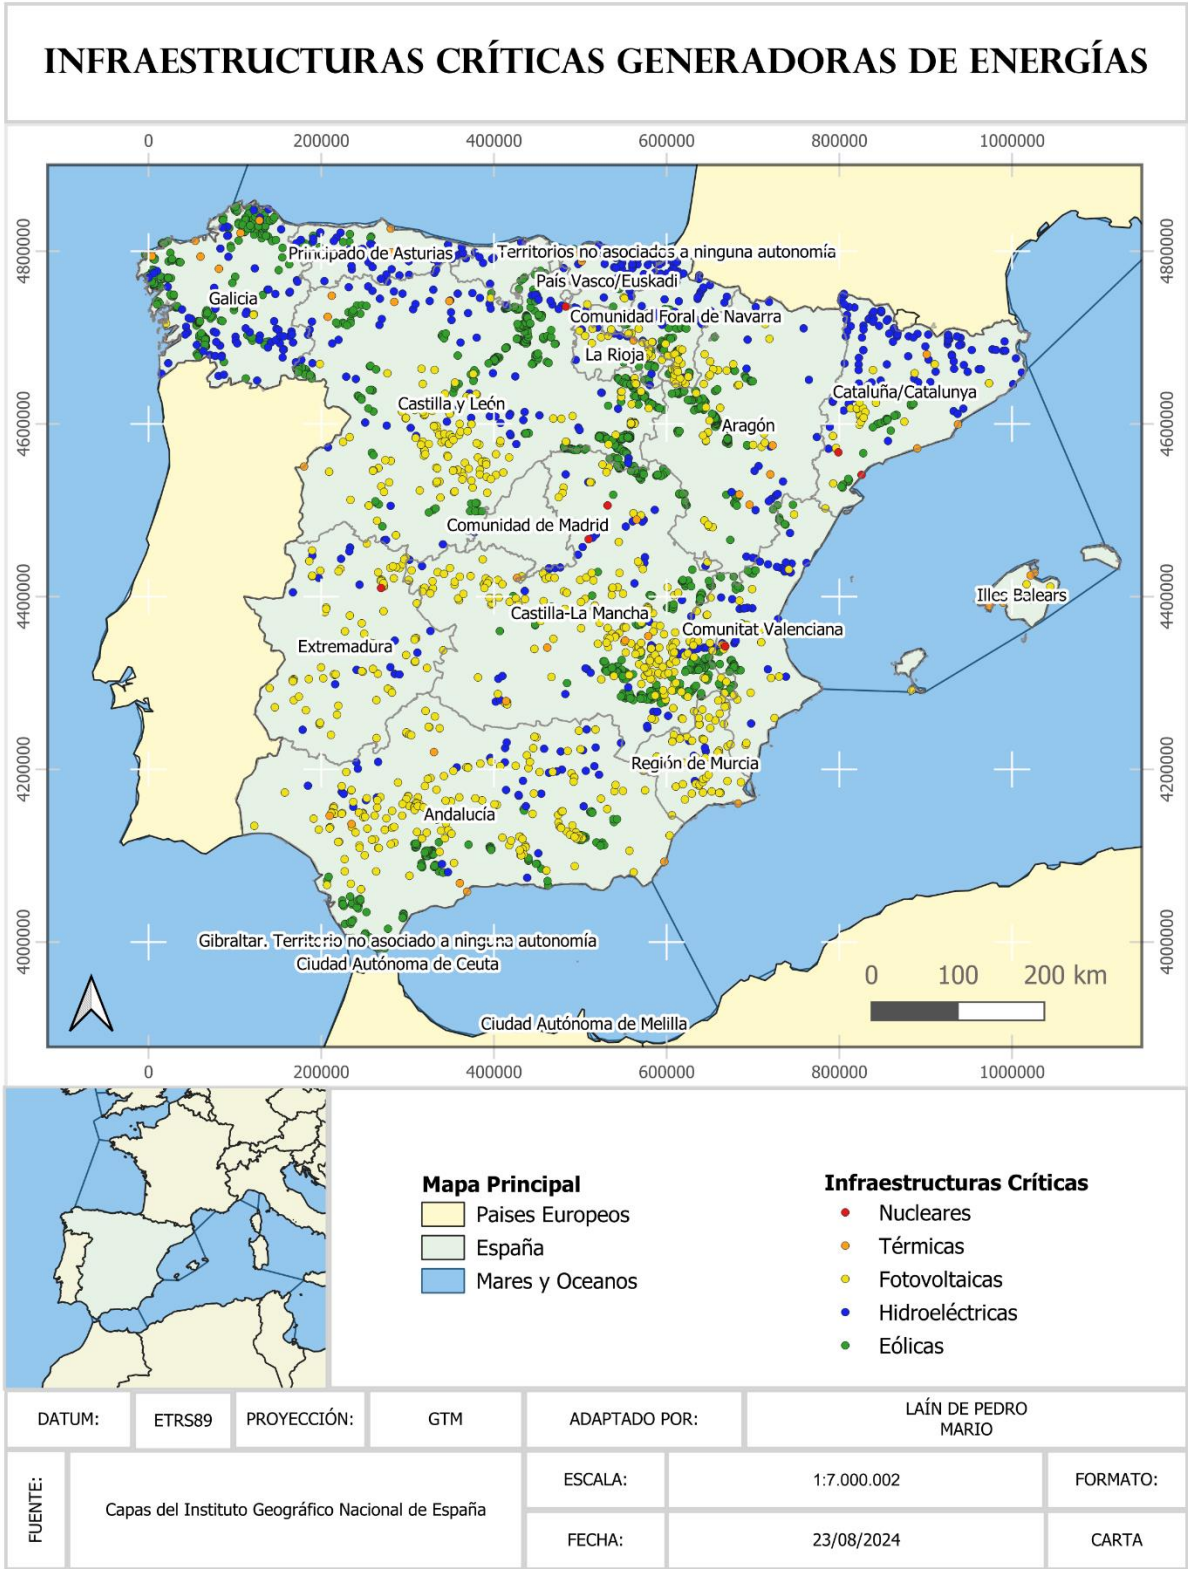


Figura 170. Mapa con la distribución de todas las infraestructuras críticas productoras de energía.

Respondiendo a las preguntas que se han formulado con anterioridad sobre donde se localizan las regiones de mayor número de afectados, las que sufrirían las consecuencias más graves si hubiera un gran apagón. En el mapa de la figura 171 se observa que es prácticamente idéntico al mapa de las zonas de riesgo de las renovables pero con algunos cambios que son debidos a las a la inclusión de las centrales nucleares y térmicas. Estos cambios se encuentran en el centro de la Península en la Comunidad Autónoma de Madrid que ahora surge como un gran foco de riesgo de afectados debido a la inclusión de las centrales nucleares de Trillo y Zorita y a la central térmica de Infiernillo (Figura 172). Esto crea una gran área de afectados que deja prácticamente el mapa de España en riesgo absoluto en las zonas más habitadas de nuestro país se puede apreciar por las curvas de nivel de afectados tan juntas que marcan la intensidad en el número de afectados, exceptuando las zonas de la España vaciada como Gaudalajara, Extremadura parte de Castilla y León y Castilla La Mancha, Otra zona donde se incrementa en riesgo es la de Cataluña ya que hemos incluido las centrales nucleares de Ascó y Valldellós y se crea cerca de ellas una zona que incrementa los daños más si cabe en la región catalana además las curvas de afectados en esa zona se cuentan por 300 mil afectados.

Otra zona donde aumenta el número de afectados es la región de Andalucía que al añadir cuatro centrales térmicas se crea una región que va desde Sevilla que ya la teníamos en el anterior mapa de zonas de riesgo debido a un ataque a las renovables hasta Ronda, Málaga y Marbella zonas muy densamente pobladas por ello se incrementa el riesgo considerablemente a que haya un mayor número de afectados. Otro cambio que se percibe claramente es en la localización de la central nuclear en Valencia de Cofrentes donde hay una acumulación masiva de plantas eólicas y solares que al introducir este elemento los afectados cambian bruscamente y se ven unas curvas de afectados muy juntas que nos indican que sería la zona de mayor riesgo de toda Valencia.

Como resumen final me gustaría decir que este sería uno de los escenarios más catastróficos donde gran parte de la población española se vería afectada por los cortes de luz indefinidos. Además las zonas de riesgo de afectados se situando justamente en la España más poblada que serían las regiones de costa, Madrid y Andalucía por lo tanto lo tanto estaríamos hablando que gran parte de la población española se vería afectada por este escenario hipotético.

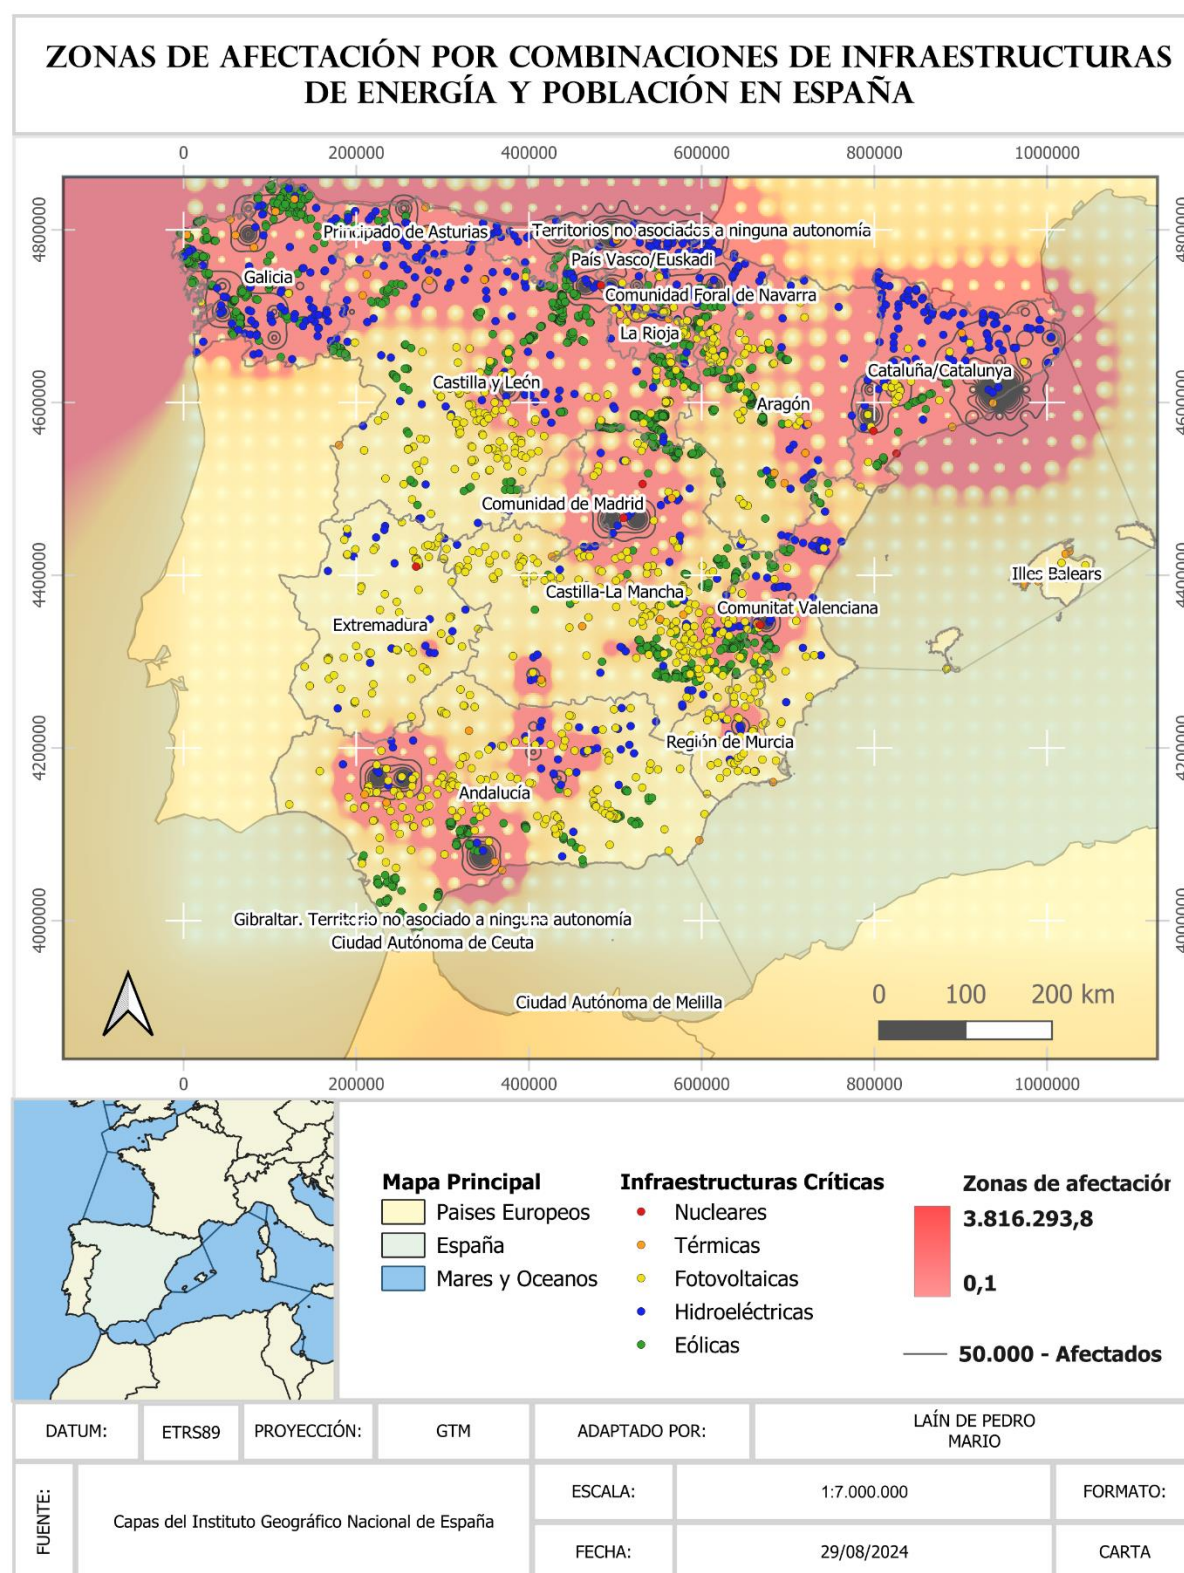


Figura 171. Zonas de afectación por combinaciones de infraestructuras de energías y población en España.

Mapa Principal

- Países Europeos
- España
- Mares y Oceanos

Infraestructuras Críticas

- Nucleares
- Térmicas
- Fotovoltaicas
- Hidroeléctricas
- Eólicas

Zonas de afectación

3.816.293,8

0,1

50.000 - Afectados

DATUM: ETRS89 **PROYECCIÓN:** GTM **ADAPTADO POR:** LAÍN DE PEDRO MARIO

ESCALA: 1:3.500.000 **FORMATO:** CARTA

FECHA: 29/08/2024

FUENTE: Capas del Instituto Geográfico Nacional de España

165

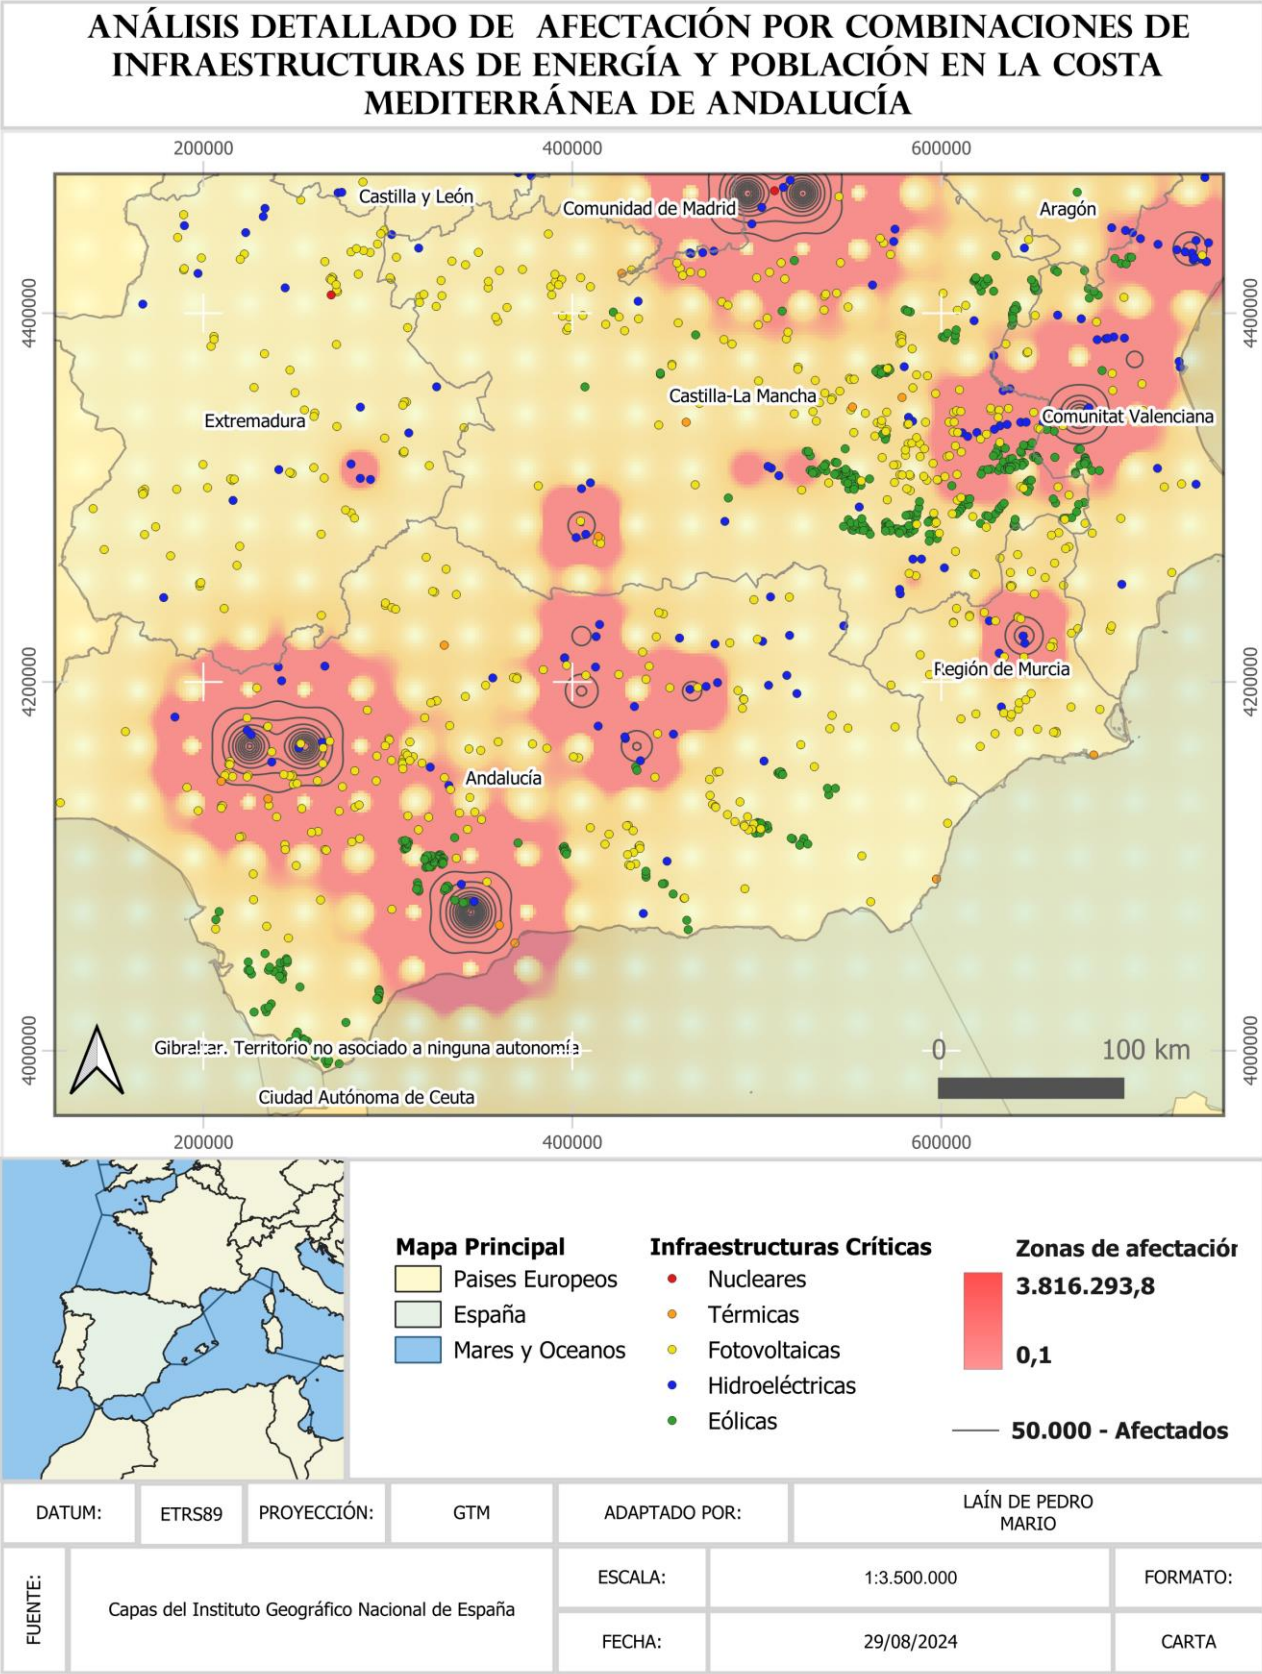


Figura 173. Análisis detallado de afectación por combinaciones de infraestructuras de energías y población en la costa mediterránea de Andalucía.

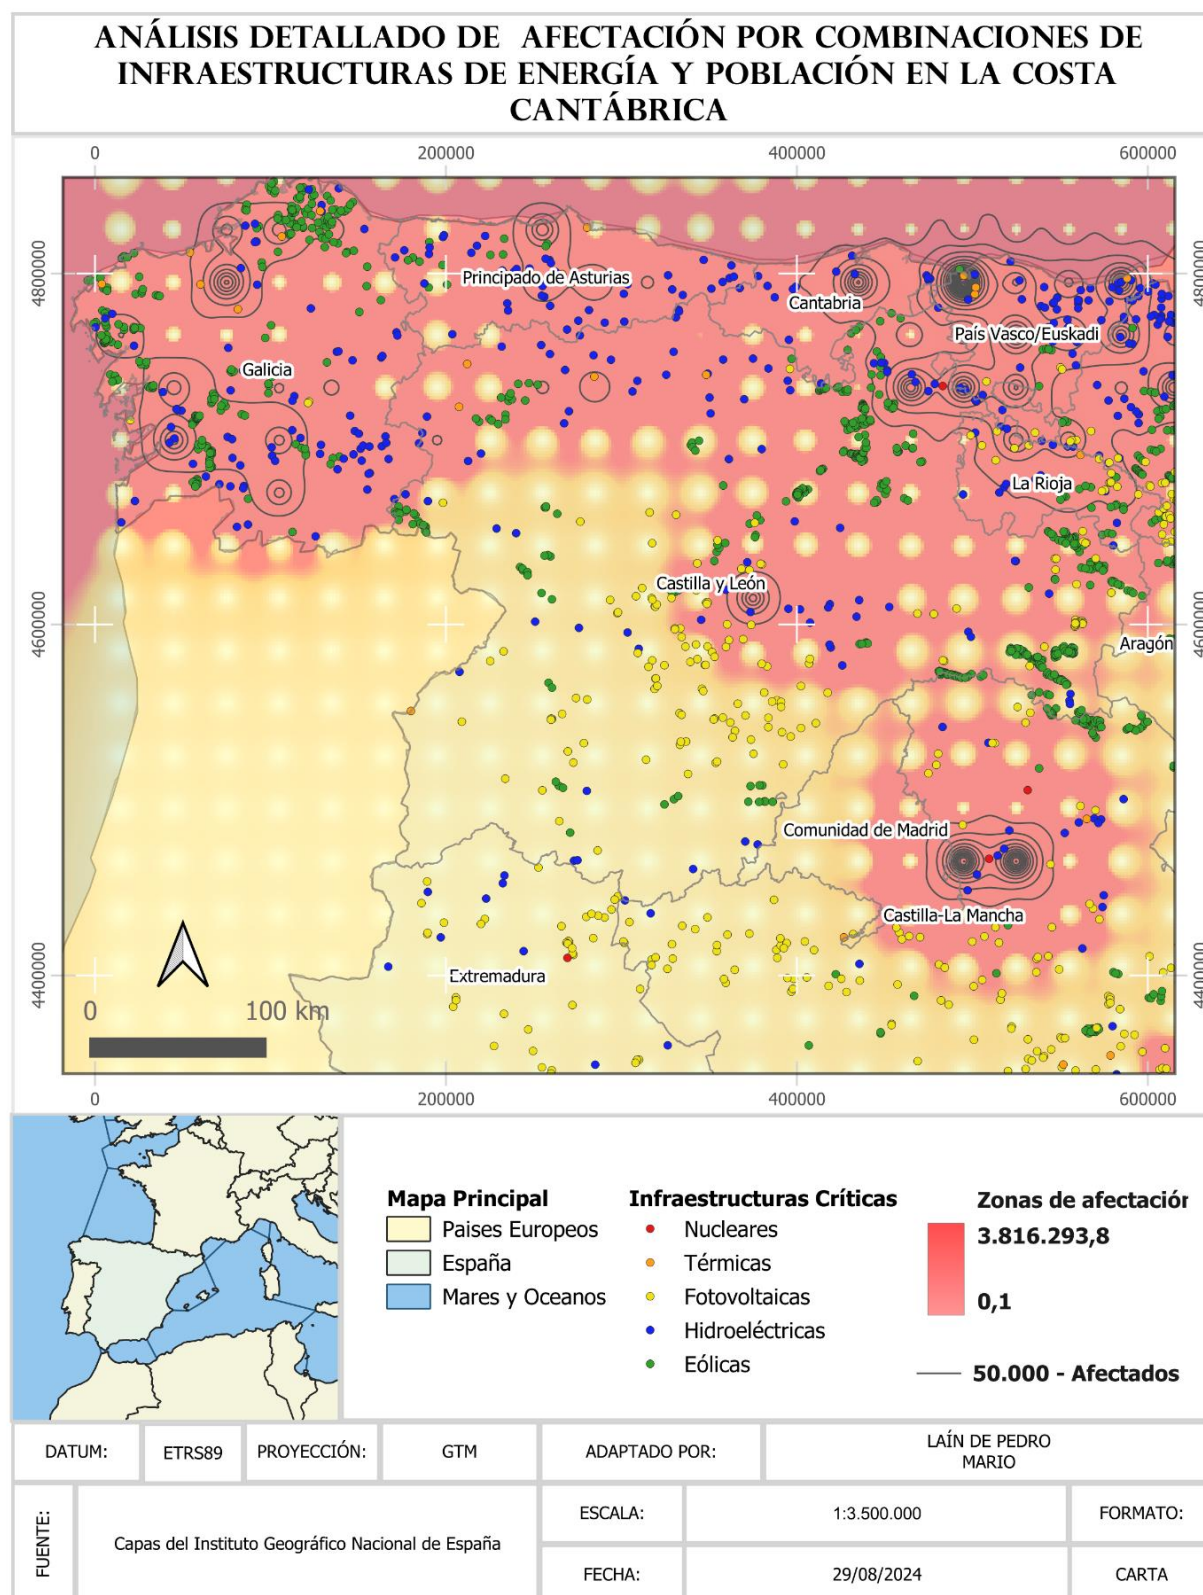


Figura 174. Análisis detallado de afectación por combinaciones de infraestructuras de energías y población en la costa Cantábrica.

6.5. Regiones de riesgo de personas afectadas por un ataque total a la producción eléctrica.

Para poder explicar la localización de hospitales, universidades y la red eléctrica en el territorio español es importante tener en cuenta varios factores socioeconómicos y geográficos.

Los hospitales se ubican de manera que se maximice la accesibilidad para la mayor parte de la población. Están localizados estratégicamente en las principales ciudades ya que son las zonas más densamente pobladas ya que de esta manera es donde pueden maximizar sus funciones. Para asegurar que todas las regiones de España tengan un acceso equitativo a los servicios de salud, los hospitales se distribuyen en varias áreas, incluyen zonas urbanas en su mayoría y algunos núcleos rurales de mayor tamaño. La proximidad a carreteras principales y a infraestructuras de transporte es crucial para la ubicación de los hospitales ya que facilitan un acceso rápido a dichas infraestructuras en caso de emergencias. Por otro la red de alto voltaje es esencial para el funcionamiento de esta infraestructura crítica como se puede observar en el mapa para el normal funcionamiento de la mayoría de sus instrumentos y herramientas médicas.

El caso concreto de las universidades, creo que hablamos con anterioridad de ellas en otro análisis. Se sitúan en las grandes ciudades y capitales regionales, donde hay una mayor concentración de población estudiantil. Presenta una distribución equitativa por toda España, para promover la educación de máximo rango en todo el país. Se pueden encontrar universidades en ciudades pequeñas, en nuestra Comunidad Autónoma tenemos el caso de que dos de las ciudades más pequeñas del país Huesca y Teruel tienen centros universitarios de algunos grados y masters. Las universidades son dependientes totales de la red eléctrica igual que los hospitales requieren una infraestructura eléctrica robusta para sus operaciones diarias, incluyendo laboratorios, instalaciones de TI etc.

Mediante los análisis que se han elaborado de distintas infraestructuras críticas, la red eléctrica es uno de los más importantes debido a que hemos creado un sistema tanto económico, social, industrial que es totalmente dependiente de la energía eléctrica para el mantenimiento del funcionamiento de la sociedad. Por lo tanto la red eléctrica está diseñada para cubrir todo el país, asegurando que tanto áreas urbanas como rurales tengan acceso a electricidad. Hay multitud de puntos estratégicos con nodos y subestaciones eléctricas para optimizar la distribución y minimizar las pérdidas de energía. Como se ha hablado en los antecedentes del marco legal, España forma parte de la Unión Europea y uno de sus principios estrella es la cooperación entre los países por lo tanto tenemos conexiones internacionales en la red de energía eléctrica con países vecinos como Francia y Portugal, garantizando la interconexión y la seguridad energética.

En el segundo mapa (figura 176) el cual nos muestra las zonas de riesgo por número de afectados, se observan áreas con diferentes niveles de afectados en base al número de población y la concentración de hospitales, universidades y suministro de electricidad mediante la red. Se podría decir que las zonas más densamente pobladas de España que son las zonas costeras del mediterráneo, del cantábrico y del atlántico como son (Valencia, Barcelona, y Bilbao, Santander, Gijón, A Coruña, Vigo y la zona de Madrid) muestran zonas de alto riesgo por número de afectados debido a la concentración de población e infraestructuras críticas en estas zonas. Estas áreas son más vulnerables porque acumulan la mayoría de las infraestructuras críticas de hospitales universidades y red eléctrica de alto voltaje. Además estas zonas presentan una dependencia energética porque presentan multitud de servicios que dependen de ella para el normal funcionamiento por lo cual el mayor riesgo que presentan en nuestro mapa. Las zonas más rurales del interior peninsular y menos densamente pobladas se puede apreciar un menor riesgo relativo, pero aun así están cubiertas para asegurar que no queden completamente desprotegidas.

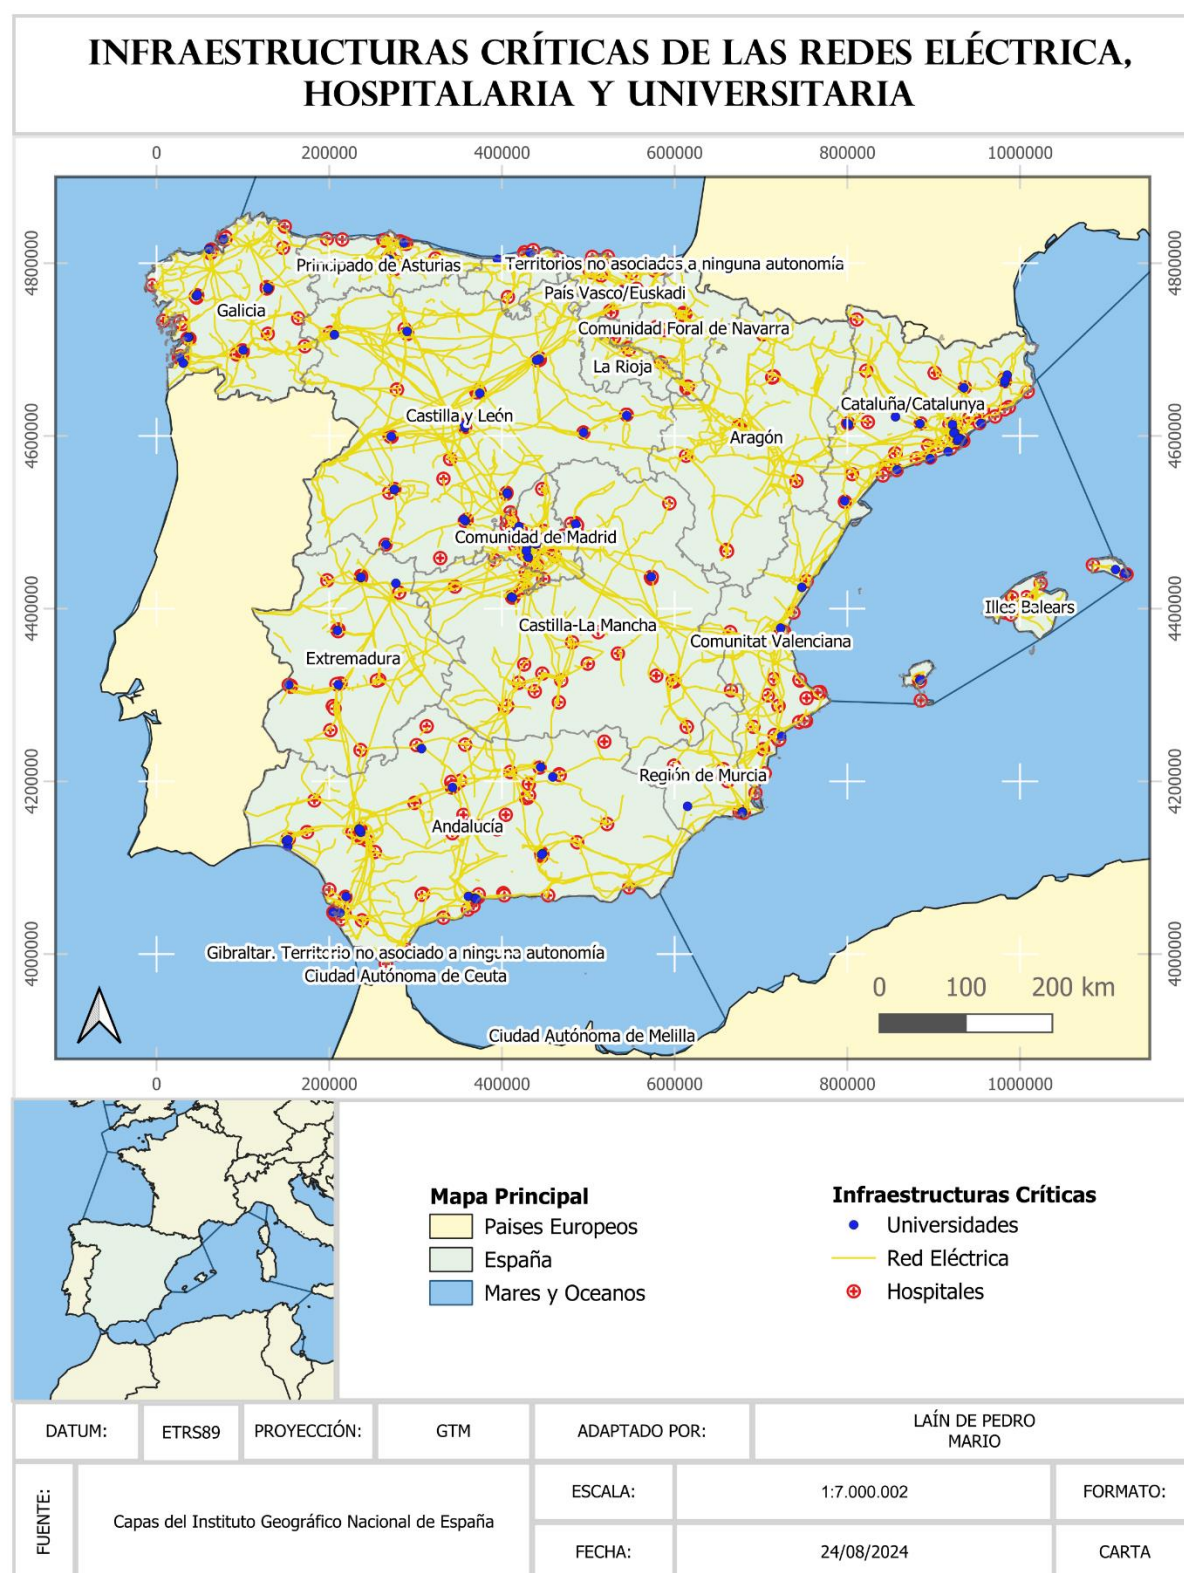


Figura 175. Mapa de la distribución de los hospitales, red eléctrica y centros universitarios.

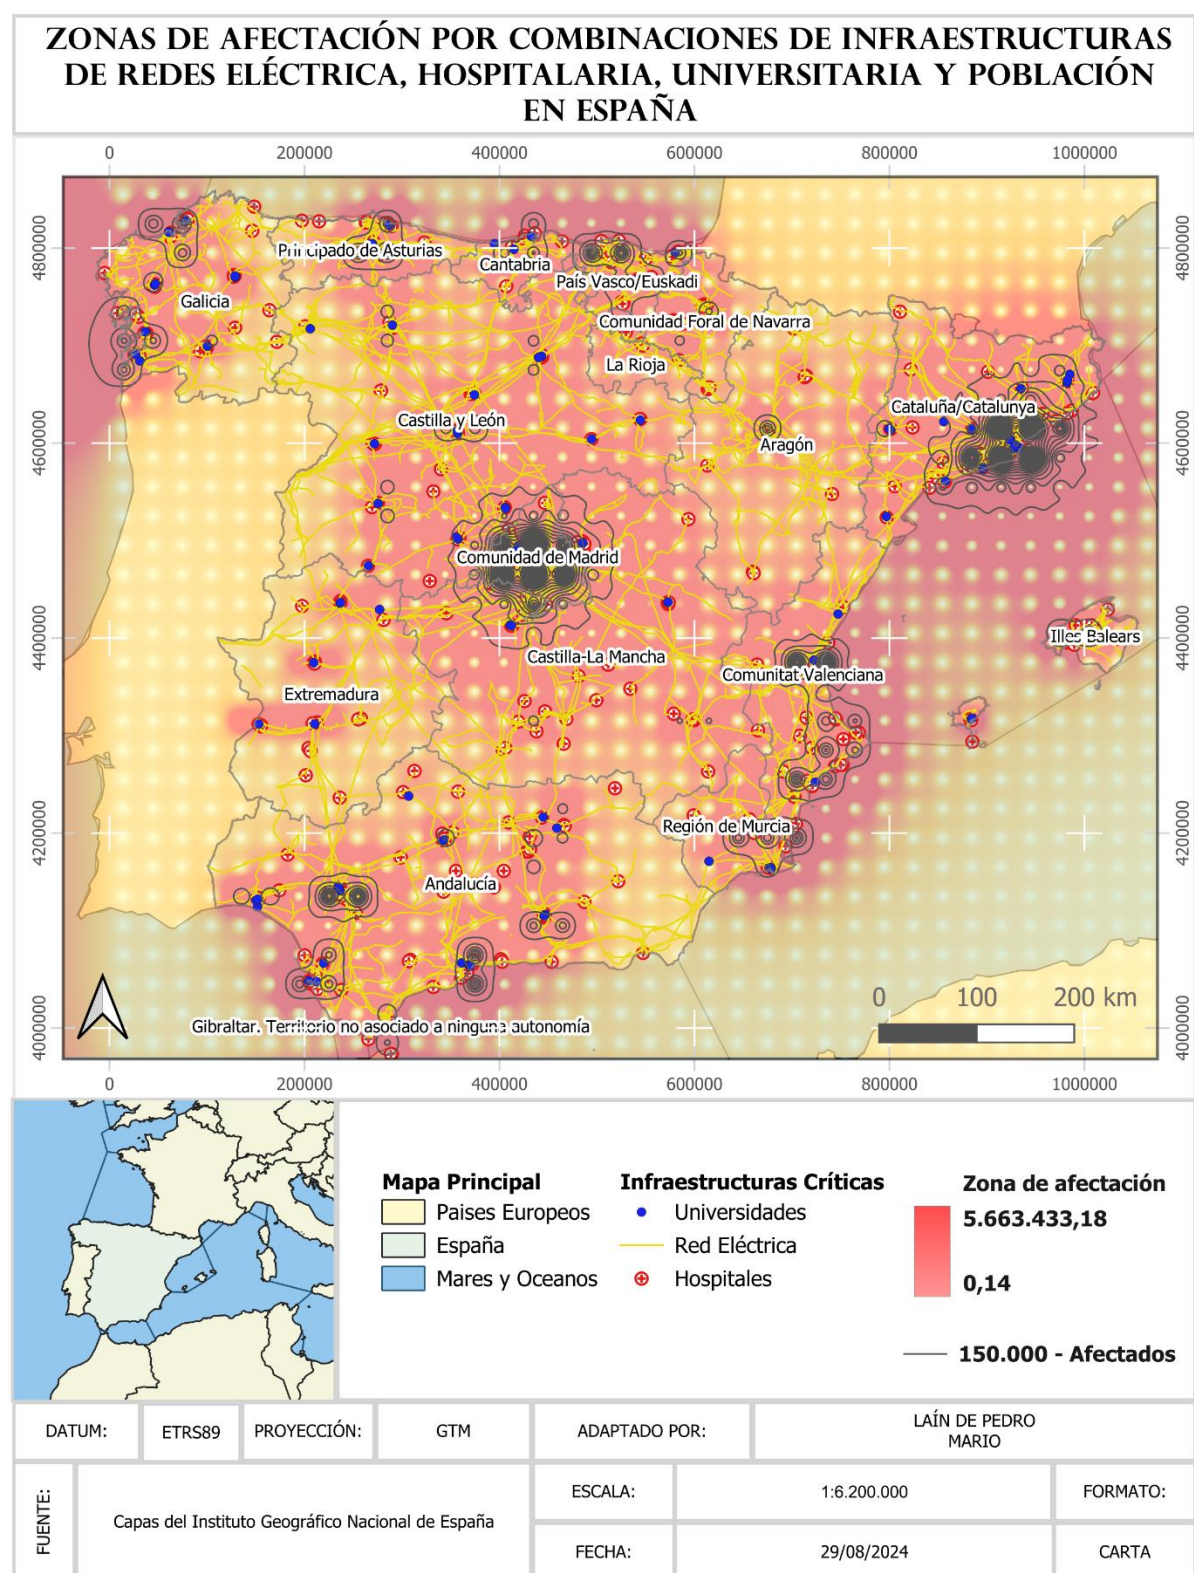


Figura 176. Regiones de máximo riesgo de afectados por combinaciones de ataque hospitales, universidades y red eléctrica.

Mapa Principal

- Países Europeos
- España
- Mares y Océanos

Infraestructuras Críticas

- Universidades
- Red Eléctrica
- Hospitales

Zona de afectación

5.663.433,18

0,14

150.000 - Afectados

DATUM: ETRS89 **PROYECCIÓN:** GTM **ADAPTADO POR:** LAÍN DE PEDRO MARIO

FUENTE: Capas del Instituto Geográfico Nacional de España

ESCALA: 1:3.500.000 **FORMATO:** CARTA

FECHA: 03/09/2024

172

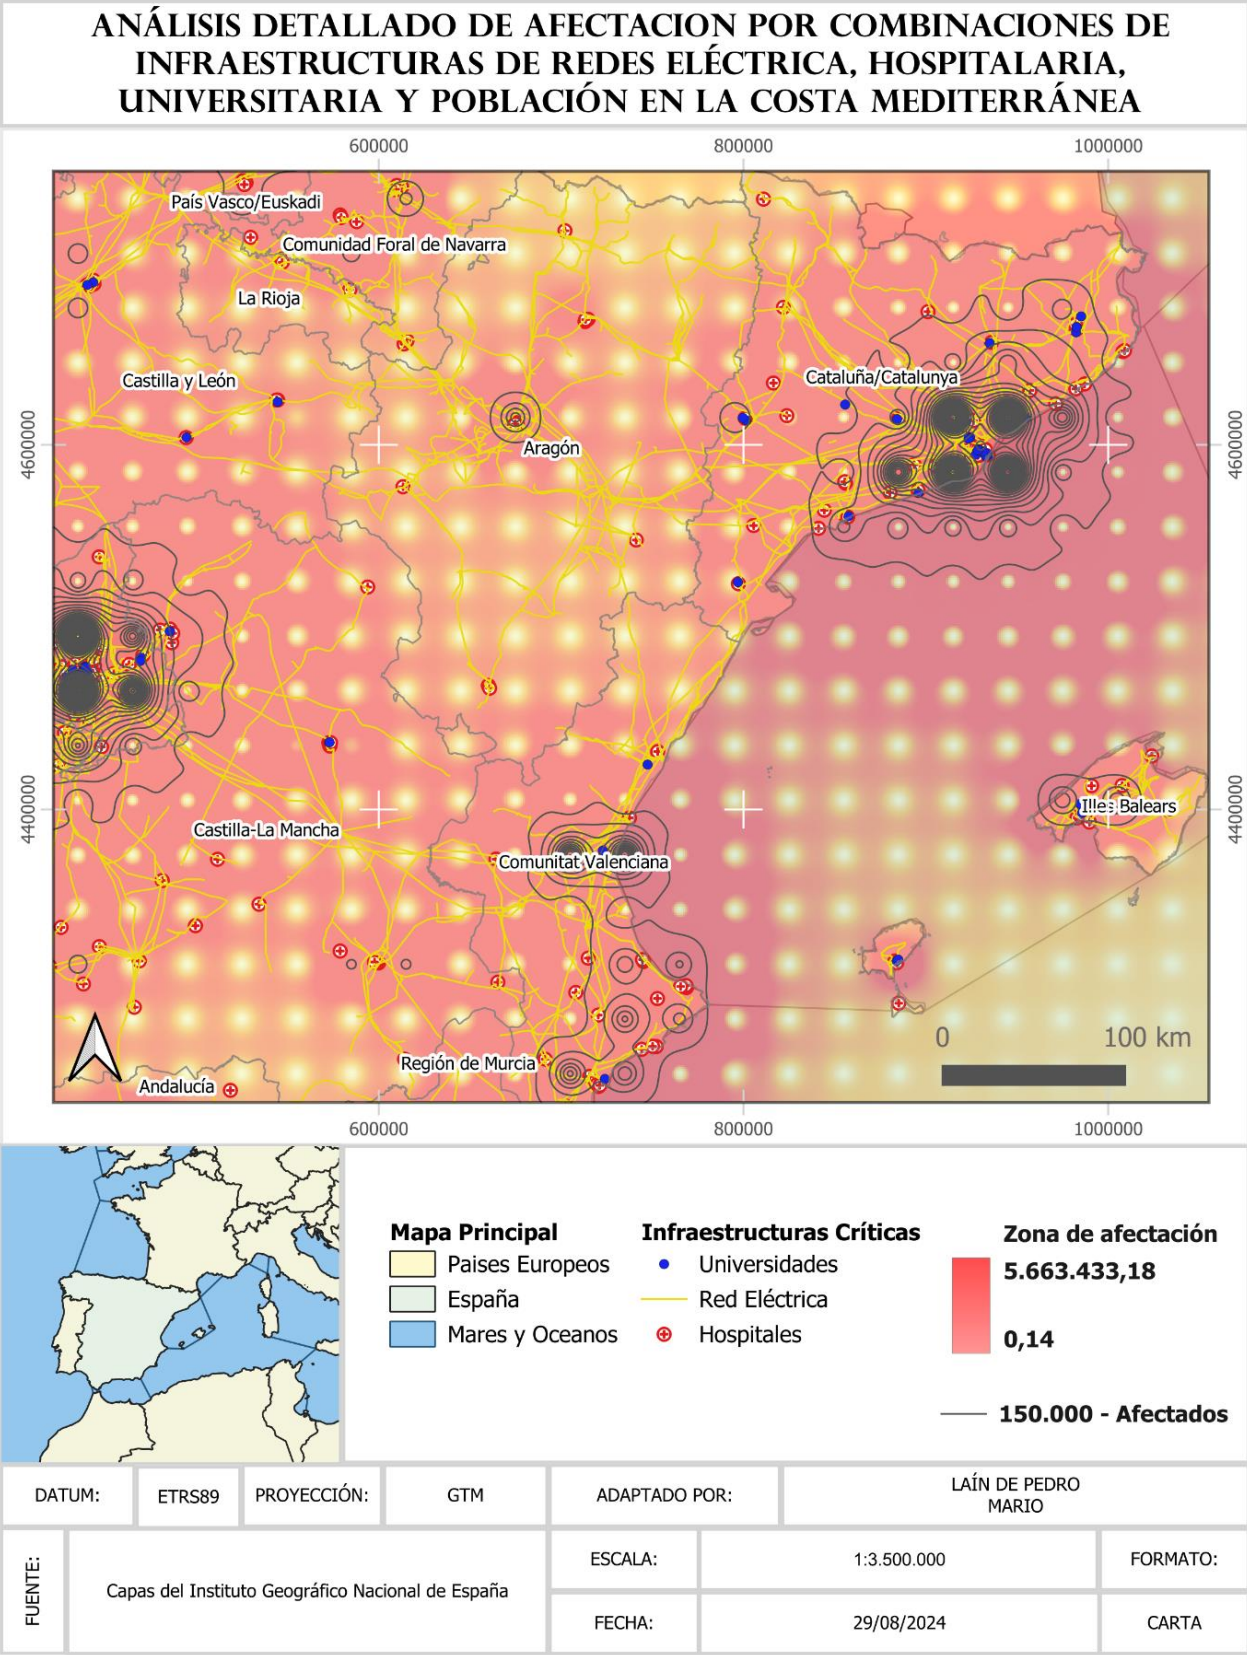


Figura 178. Análisis detallado de afectación por combinaciones de ataque hospitales, universidades y red eléctrica en la costa Mediterránea.

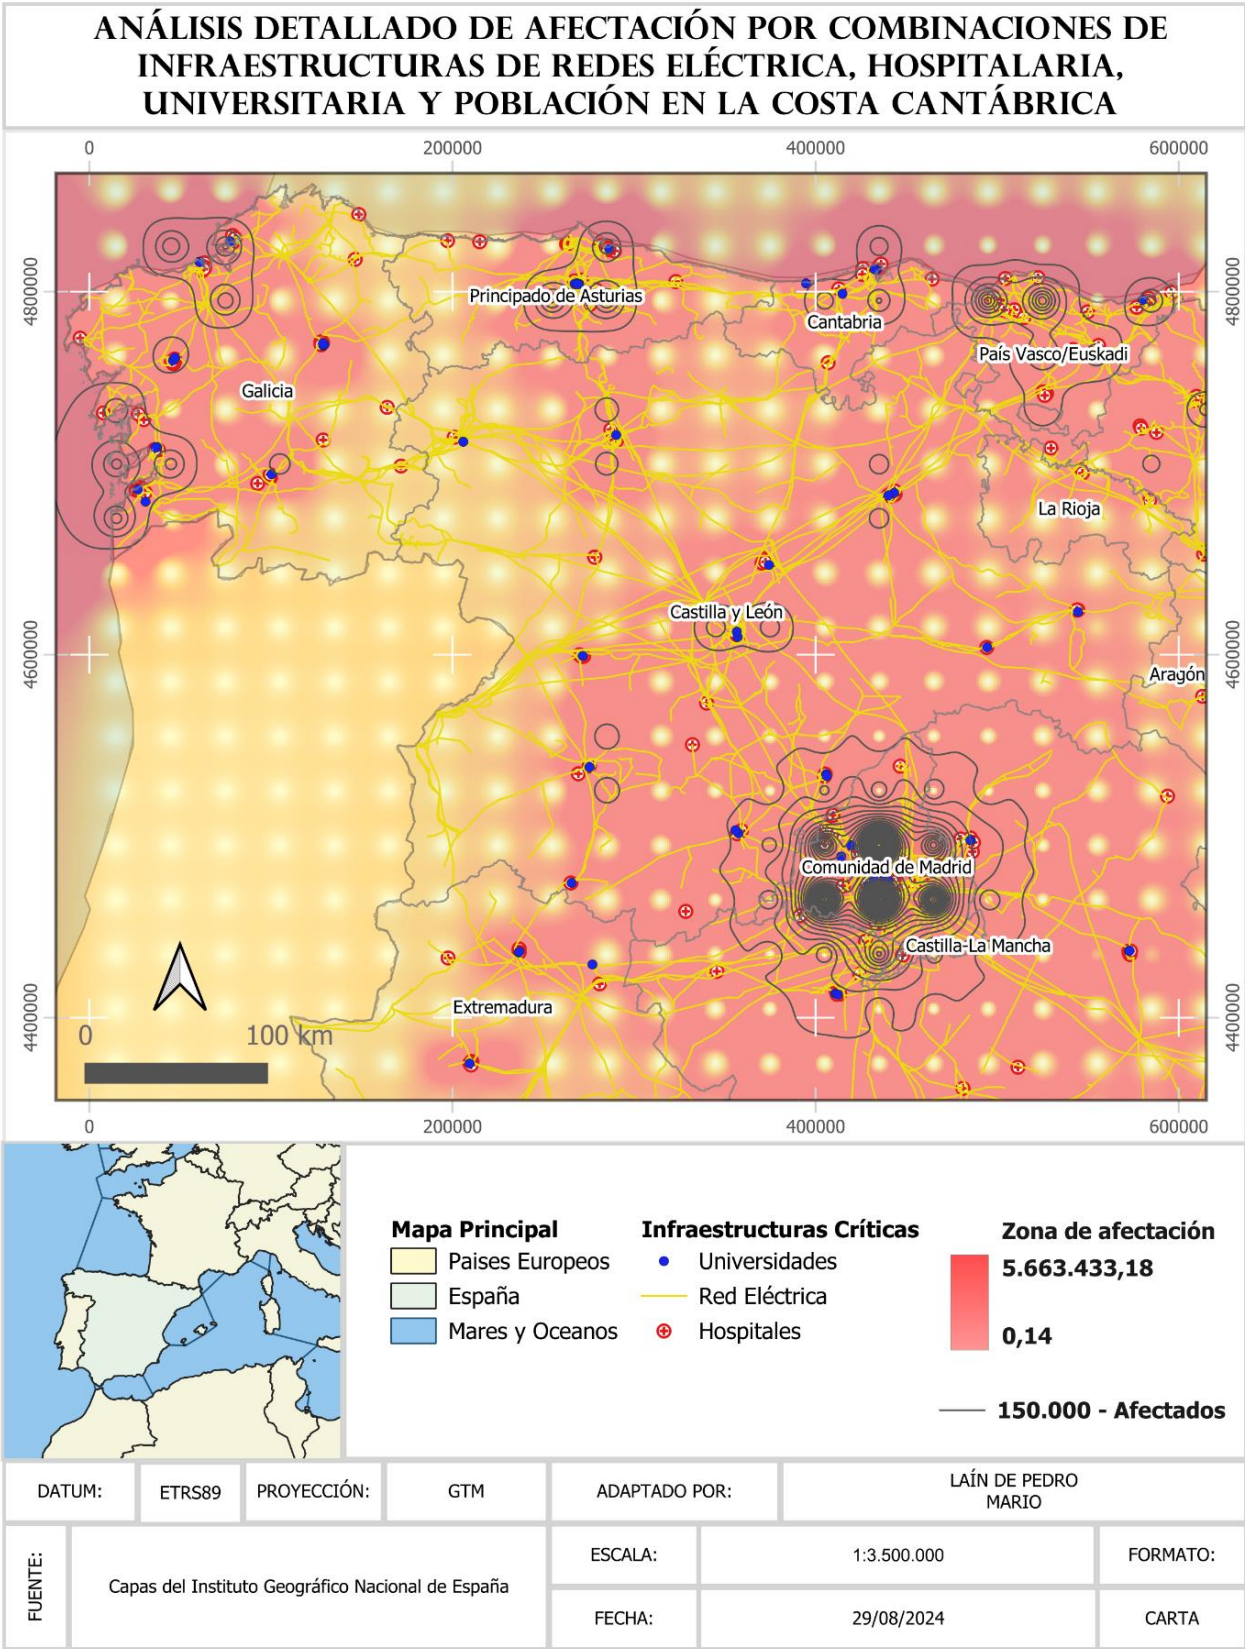


Figura 179. Análisis detallado de afectación por combinaciones de ataque hospitales, universidades y red eléctrica en la costa Mediterránea.

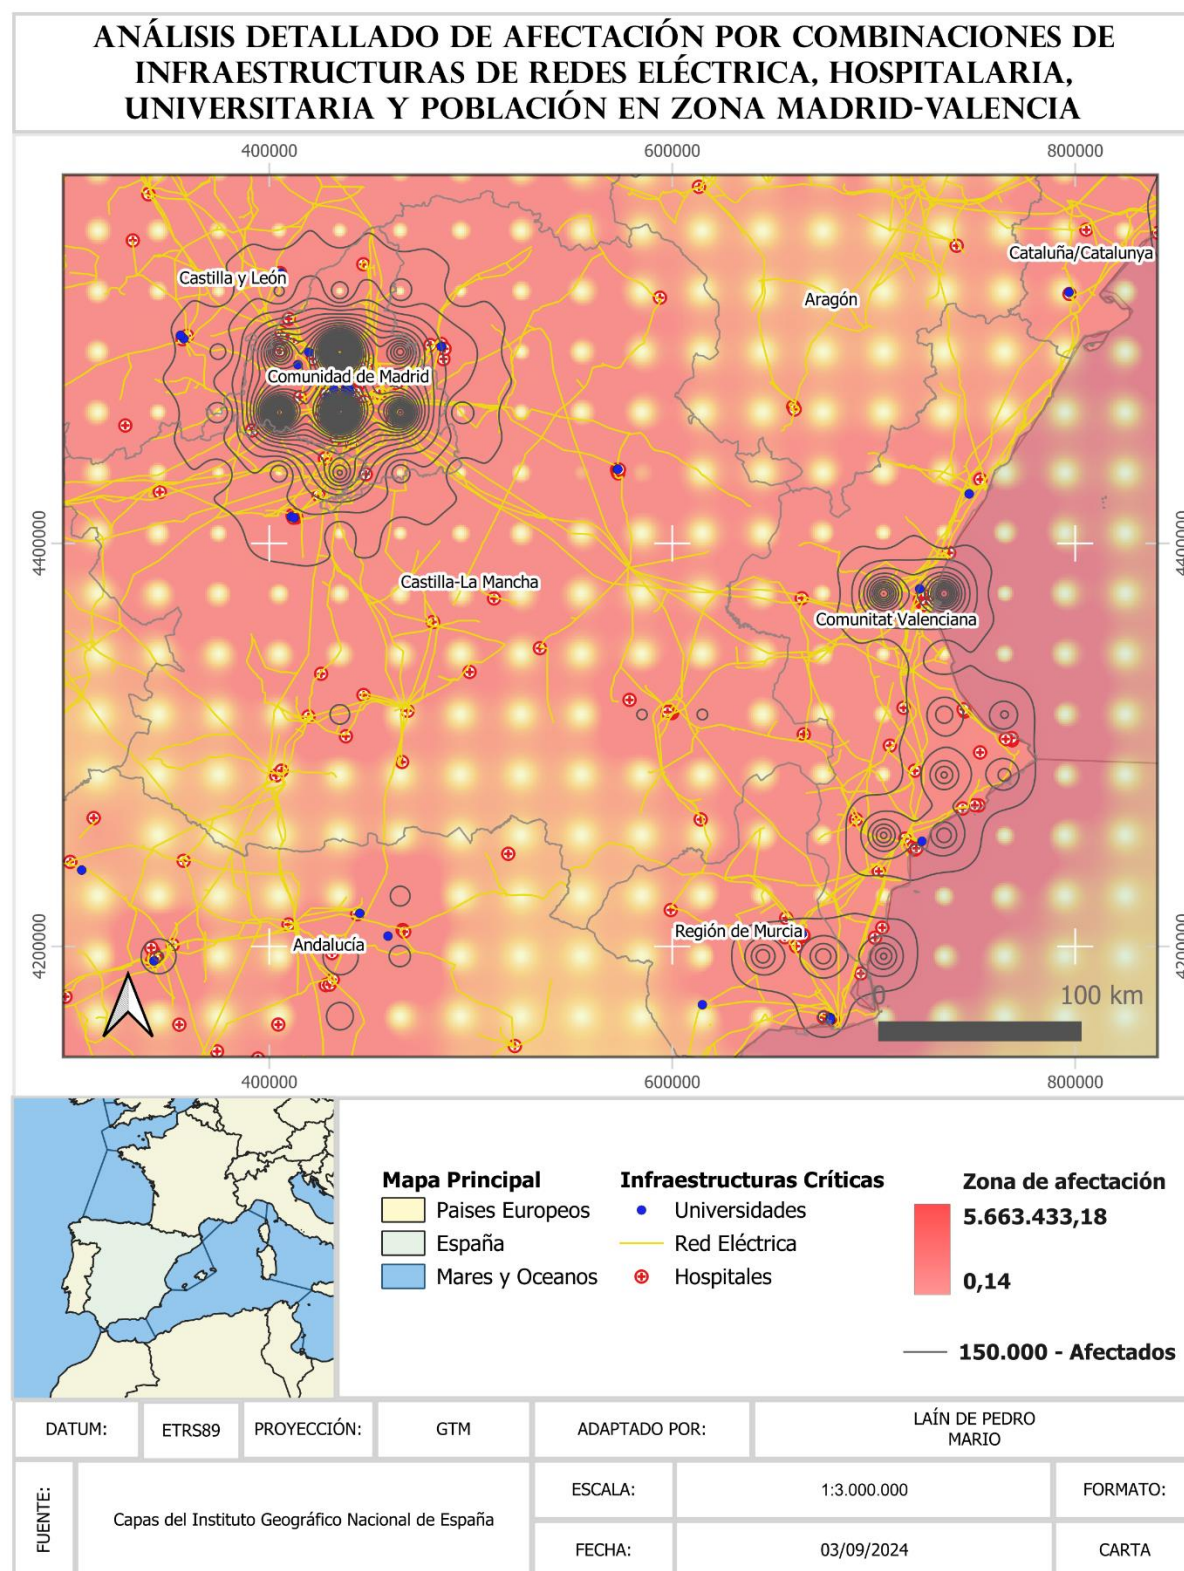


Figura 180. Análisis detallado de afectación por combinaciones de ataque hospitales, universidades y red eléctrica en la zona Madrid-Valencia.

7. Discusión

Los principales hallazgos de este estudio geográfico de escenarios de ataques a combinaciones de infraestructuras críticas y sus afectados son las siguientes: regiones costeras de España como son la costa Mediterránea (Barcelona y su área metropolitana, Tarragona, Castellón, Alicante, Valencia, Almería) y algunas de las ciudades más pobladas de Andalucía como son (Málaga, Marbella, Ronda, Cádiz, Huelva) y en la costa del mar Cantábrico sucede lo mismo en (San Sebastián, Bilbao y su área metropolitana, Santander, Gijón, Oviedo) y la parte de Galicia de zona Atlántica con (el Ferrol, A Coruña, Santiago de Compostela, Pontevedra y Vigo) además de la capital Madrid, con 6.5000000 de potenciales víctimas en caso de un ataque combinado a las infraestructuras de trasportes.

Los resultados han permitido alcanzar los objetivos planteados, que buscaba identificar todas aquellas regiones críticas en distintos escenarios hipotéticos de ataque a diferentes tipos de infraestructuras críticas dentro del territorio español. Otro pregunta que se ha respondido mediante datos con nuestros análisis es si las zonas de la España vaciada son menos propensas a riesgos y como se ha comprobado en la mayoría de los mapas resultantes, se puede afirmar que estas zonas de la España vaciada (Guadalajara, Extremadura, Teruel, Soria, Ciudad Real, Albacete, Cuenca, Salamanca, Ávila, Segovia, Zamora, Palencia, León) son mucho menos propensas a sufrir riesgos asociados a los ataques debido al menor número de infraestructuras críticas y a las menores tasas de densidad de población por lo tanto el número de afectados disminuye considerablemente. Cuestionar formas de poblamiento excesivamente concentrado, aunque tenga algunas ventajas desde el punto de vista económico, en caso de una intervención terrorista o militar contra España puede incrementar los riesgos. Esto plantea una cuestión estratégica relevante: ¿Podría la reubicación de ciertas infraestructuras críticas hacia estas áreas menos pobladas reducir el riesgo en las zonas?

Si bien la reubicación estratégica de infraestructuras críticas podría mitigar el riesgo en las áreas de mayor densidad, es necesario abordar varios desafíos logísticos y estratégicos antes de implementar tales medidas. Esto incluye la evaluación de la viabilidad en términos de acceso a servicios esenciales, transporte, y la infraestructura necesaria en las áreas menos pobladas.

Otros estudios refuerzan la importancia de considerar la concentración de infraestructuras críticas en áreas urbanas. Matos y Teixeira (2023) realizaron un análisis de vulnerabilidad espacial de infraestructuras críticas en el centro histórico de Guimarães, Portugal y encontraron que dicha concentración amplifica significativamente los riesgos ante eventos extremos.

Otro de los estudios que concuerda con los resultados obtenidos es el de Fekete et al. (2015) que explora el impacto de desastres en áreas urbanas, analizando la exposición y la vulnerabilidad de infraestructuras críticas en un contexto de inundaciones y apagones. Este estudio enfatiza la

importancia de la densidad de población y la interconexión de las infraestructuras críticas en las zonas urbanas como factor clave para aumentar la vulnerabilidad de las ciudades. Esto refuerza mi hipótesis de que las áreas urbanas, particularmente todas aquellas ciudades de la costa Mediterránea y Cantábrica que he citado, son especialmente vulnerables por su alta concentración de infraestructuras y población. Asimismo, Frigerio y De Amicis (2018) han realizado una investigación que sugiere que las disparidades entre áreas urbanas y rurales en términos de riesgo y vulnerabilidad están estrechamente vinculadas a la densidad de infraestructuras críticas y la concentración de la población en estas áreas. Este hallazgo complementa nuestros resultados, confirmando que la vulnerabilidad territorial es una función tanto de la densidad de infraestructuras críticas como de la concentración demográfica.

Las implicaciones de los resultados de la investigación que se ha llevado a cabo tienen importantes implicaciones para la planificación y la gestión de todas las infraestructuras críticas estudiadas en España. La identificación de las zonas de mayor riesgo permite a los responsables de la seguridad nacional priorizar la protección y refuerzo de infraestructuras en estas áreas vulnerables. Además se ha sugerido que si hubiera la posibilidad de reubicación de estas infraestructuras críticas hacia regiones menos pobladas se podría llegar a reducir aunque se requiere una evaluación cuidadosa de los desafíos logísticos. En el contexto geopolítico actual, donde las amenazas cibernéticas y físicas están en aumento, estos hallazgos subrayan la necesidad de una estrategia de seguridad integral que considere tanto la localización geográfica como la interconectividad de las infraestructuras críticas.

Metodología

Es importante hablar dentro de la discusión de todas las limitaciones que se han tenido en la elaboración del proyecto. En primer lugar, la disponibilidad y la calidad de los datos geoespaciales pueden haber afectado a la precisión de los análisis. Aunque se utilizaron fuentes de datos confiables el IGN, las limitaciones inherentes a los datos siempre están como son la resolución espacial y la actualidad de los datos podrían haber influido en los resultados. Además, la metodología utilizada para los análisis geoespaciales y el método idw, aunque efectivas, se podrían beneficiar de la incorporación de técnicas más avanzadas o complementarias que permitieran una mayor precisión en la identificación de las zonas de riesgo. Finalmente, el hardware utilizado para todo el procesamiento de datos presento limitaciones que ralentizaron los análisis y afectaron a la capacidad de manejar grandes volúmenes de datos de manera óptima.

Para poder analizar el efecto de un posible ataque terrorista, cibernético o de otro Estado contra España se ha estudiado la distribución de la población y las infraestructuras, no obstante el procesado de la información hubiera sido imposible sin herramientas como Python y SIG. Uno de los objetivos esenciales del proyecto fue el desarrollo de un script en Python que permitiera identificar combinaciones de infraestructuras críticas que generaran los escenarios más peligrosos. Este objetivo

se ha desarrollado exitosamente como se ha podido comprobar en el proyecto, y los resultados obtenidos han sido visualizados utilizando el método idw, que ha demostrado ser efectivo en la representación espacial de los datos de riesgo. Este método fue seleccionado por sus múltiples beneficios, incluyendo su capacidad para generar superficies continuas y representar con precisión las zonas de influencia alrededor de las infraestructuras críticas.

En este contexto, surge la oportunidad de mejorar el procesamiento de datos utilizando herramientas en la nube y alquilando servidores de alto rendimiento. Estos entornos de computación en la nube ofrecen varias ventajas, como la escalabilidad, la velocidad de procesamiento mejorada y la capacidad de manejar grandes volúmenes de datos de manera más eficiente. Implementar estas tecnologías podría no solo acelerar el procesamiento de los datos, sino también mejorar la precisión y complejidad de los análisis que se pueden realizar. Esto permitiría manejar conjuntos de datos aún más grandes y realizar simulaciones más detalladas, abriendo la puerta a análisis más sofisticados en futuros proyectos.

Propuestas

Para finalizar el apartado de discusión, me gustaría incluir algunas recomendaciones para investigaciones futuras como serían la utilización de otros tipos de infraestructuras críticas que no se han abordado en este estudio como podría ser la red de abastecimiento de agua o de gas, dos de las infraestructuras de una importancia suprema aunque para este análisis se tendrían que utilizar escalas mayores pero como nuestro proyecto es modulable no habría ningún problema, lo único que se incrementarían mucho los datos y el tiempo de análisis de los mismos. Además, se podrían considerar el uso de metodologías alternativas para el análisis geoespacial, como el aprendizaje automático para la predicción del riesgo o la simulación de escenarios más complejos con muchas más variables.

8. Conclusiones

Declarar lo primero de todo que algunas de las regiones de España están en riesgo serio de sufrir un grave ataque y provocar una gran cantidad de víctimas como puede ser el ataque a las infraestructuras de transporte. En los ejemplos anteriores podemos ver como tenemos varios centroides en Madrid donde habría más de 6.500.000 de afectados o 4.300.000 afectados que podrían sufrir graves consecuencias o verse afectadas. Por el contra partida , se ha confirmado la hipótesis, de que no todo el territorio está sujeto a los mismos riesgos, la concentración de población vulnerable es mayor en las zonas más densamente pobladas sin embargo, no es la única variable que explica la exposición. Los factores más relevantes son la presencia de infraestructuras críticas y su tipo; las más peligrosas son las combinaciones de los transportes, las relacionadas con la producción de energía y las infraestructuras de defensa y educativas sonde en este caso concreto tenemos varios centroides donde los valores de afectados llegan a 6.500.000 afectados y 4.300.000 afectados, en cambio, otras como las

infraestructuras productoras de energías renovables que están más dispersas por el territorio y en zonas de una menor acumulación de población presentan un riesgo menor con valores que oscilan entre los 2.000.000 millones de afectados. Las regiones de España más vulnerables a ataques serían las áreas costeras y grandes ciudades como Madrid, Barcelona, Bilbao, Valencia se comprobó en los múltiples mapas presentados para el proyecto, que estas zonas concentran el mayor riesgo, mientras que las zonas menos pobladas de España presentan vulnerabilidades significativamente menores. Estos hallazgos no solo responden a las preguntas de investigación planteadas, sino que también subrayan la importancia de la planificación estratégica de las infraestructuras críticas. Además tenemos zonas críticas poniendo un ejemplo muy representativo en las zonas que encontramos la central nuclear. Sobre todo en los casos de las centrales de Valldellós y Ascó dos centrales nucleares que se encuentran muy juntas las cuales podrían causar más de 4.000.000 de afectados.

La contribución del estudio al campo del análisis geoespacial y la seguridad de las infraestructuras es haber trabajado con Python para realizar el modelo basado en escenarios hipotéticos de ataques. Se ha desarrollado una herramienta de gran utilidad para otros escenarios geográficos o para analizar los riesgos presentes en infraestructuras críticas de otros países y así poder obtener ventajas ante los enemigos. Al ser todo el modelo replicable puede servir para futuras investigaciones en amplios campos de estudio o para agencias gubernamentales para la planificación de la seguridad de las diferentes naciones del mundo.

Los resultados tienen aplicaciones prácticas en la planificación y protección de las infraestructuras más importantes para el estado español y también de cara a intervenciones de apoyo al ejército como herramienta para una mejor protección de sus zonas militares el estudio de los países enemigos. Las zonas identificadas como de mayor riesgo pueden ser priorizadas en términos de inversión en seguridad y refuerzo asegurando que los recursos se destinen a las áreas de mayor riesgo o vulnerabilidad, lo que contribuiría a la resiliencia del país ante posibles amenazas. Estos hallazgos podrían influir en la creación o revisión de normativas urbanísticas, fomentando la construcción y el diseño de infraestructuras con mayores estándares de seguridad. Identificando estas áreas y sus infraestructuras críticas más vulnerables pueden desarrollar planes de evacuación y respuesta más efectivos en caso de incidentes. Utilizando los escenarios desarrollados para realizar simulacros y capacitar a los equipos de emergencias y la población en las respuestas a incidentes específicos.

Para finalizar este proyecto, saber que nos encontramos en un contexto geopolítico global muy candente donde las amenazas a infraestructuras críticas son cada vez más complejas y diversas, este estudio resalta la importancia de integrar el análisis geoespacial dentro de la planificación de la seguridad nacional. Este nos dará la capacidad de adelantarnos y así poder mitigar futuros riesgos en nuestra infraestructuras y por descontado a la población que se relaciona con ellas. Mediante estas

herramientas podemos proteger a la población y la economía de un país. Este trabajo establece una base sólida para futuras investigaciones en la gestión de infraestructuras críticas, fortaleciendo la resiliencia de las sociedades modernas ante los desafíos que nos deparará el siglo XXI.

9. Bibliografía

Archivos GeoJSON del Instituto Geográfico Nacional

1. Instituto Geográfico Nacional. (2023). Depósitos de Combustibles [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
2. Instituto Geográfico Nacional. (2023). Embalses [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
3. Instituto Geográfico Nacional. (2023). Estaciones de Telecomunicaciones [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
4. Instituto Geográfico Nacional. (2023). Hospitales y Centros de Salud [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
5. Instituto Geográfico Nacional. (2023). Red de Carreteras (Autopistas y Autovías) [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
6. Instituto Geográfico Nacional. (2023). Red Hidrográfica (Ríos Principales) [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
7. Instituto Geográfico Nacional. (2023). Centrales Eléctricas (Nucleares, Eólicas, Solares y Térmicas) [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
8. Instituto Geográfico Nacional. (2023). Estaciones de Tren y Líneas de AVE [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
9. Instituto Geográfico Nacional. (2023). Aeropuertos [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
10. Instituto Geográfico Nacional. (2023). Puertos [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
11. Instituto Geográfico Nacional. (2023). Zonas Universitarias [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>
12. Instituto Geográfico Nacional. (2023). Zonas Militares [Archivo GeoJSON]. SIGNA - Visualización y análisis. Recuperado el 15 de junio de 2023, de <http://signa.ign.es/signa/>

Artículos y publicaciones.

1. Durumeric, Z., Ma, Z., & Bailey, M. (2014). Analysis of the Heartbleed OpenSSL Bug. In Proceedings of the 2014 Conference on Internet Measurement Conference (IMC '14). ACM, New York, NY, USA, 485-498. <https://doi.org/10.1145/2663716.2663755>
2. Miranzo, M., & Del Río, C. (2014). La protección de infraestructuras críticas. UNISCI.
3. OTAN. (2022). Tratado del Atlántico Norte. Disponible en: [enlace a la fuente].
4. Europol. (2004). EU Terrorism Situation and Trend Report.
5. European Union Agency for Cybersecurity (ENISA). (2018). Threat Landscape Report. Disponible en: <https://www.enisa.europa.eu/publications/enisa-threat-landscape-report-2018>
6. Smith, J., & Jones, R. (2019). Military Capabilities in the Cyberspace Era. Journal of Defense Studies, 12(4), 234-250.
7. Doe, J. (2018). Weapons of Mass Destruction and Cyber Attacks: Modern Threats. Global Security Review, 10(2), 123-145.

8. Johnson, M. (2020). Violent Groups and Weak States: Impacts on Infrastructure. *International Journal of Security Studies*, 15(3), 301-320.
9. García, L. (2017). Amenazas a las Infraestructuras Críticas en España. *Revista de Seguridad Nacional*, 9(1), 45-60.
10. Organismo Internacional de Energía Atómica (OIEA). (2020). Reporte Anual sobre Seguridad Nuclear. Disponible en: [enlace a la fuente].
11. Fondo Monetario Internacional (FMI). (2019). Informe sobre el Crimen Organizado. Disponible en: [enlace a la fuente].
12. United Nations Office on Drugs and Crime (UNODC). (2018). World Drug Report. Disponible en: [enlace a la fuente].
13. Gobierno de España. (2013). Estrategia Española de Seguridad. Disponible en: [enlace a la fuente].

Documentos oficiales y Directivas

1. Comisión Europea. (2004). Comunicación de la Comisión sobre la Protección de Infraestructuras Críticas en la lucha contra el terrorismo. Disponible en: [enlace a la fuente].
2. Gobierno de España. (2013). Estrategia Española de Seguridad. Disponible en: [enlace a la fuente].
3. Miranzo, M., & Del Río, C. (2014). La Protección de Infraestructuras Críticas. UNISCI. Disponible en: [enlace a la fuente].
4. Comisión Europea. (2004). Comunicación de la Comisión sobre Prevención, Preparación y Respuesta a los Ataques Terroristas. Disponible en: [enlace a la fuente].
5. Comisión Europea. (2004). Comunicación de la Comisión sobre la Preparación y Gestión de las Consecuencias del Terrorismo. Disponible en: [enlace a la fuente].
6. Comisión Europea. (2006). Comunicación de la Comisión sobre el Programa Europeo para la Protección de Infraestructuras Críticas. Disponible en: [enlace a la fuente].
7. Comisión Europea. (2008). Comunicación de la Comisión sobre la Red de Información sobre Alertas en Infraestructuras Críticas (CIWIN). Disponible en: [enlace a la fuente].
8. Consejo Europeo. (2008). Directiva 2008/114/CE. Disponible en: [enlace a la fuente].
9. Comisión Europea. (2004). Comunicación 702 de la Comisión Europea. Disponible en: [enlace a la fuente].
10. Frattini, F. (2004). Discurso del Comisario de Justicia, Libertad y Seguridad de la UE. Disponible en: [enlace a la fuente].
11. Parlamento Europeo y del Consejo. (2022). Directiva 2022/2557 sobre la resiliencia de las entidades críticas. *Diario Oficial de la Unión Europea*.
12. Aven, T., & Renn, O. (2010). *Risk Management and Governance: Concepts, Guidelines, and Applications*. Springer.
13. Cutter, S. L., Boruff, B. J., & Shirley, W. L. (2003). Social Vulnerability to Environmental Hazards. *Social Science Quarterly*, 84(2), 242-261.
14. European Commission. (2022). Directive 2022/2557 of the European Parliament and of the Council of 14 December 2022 on the resilience of critical entities. *Official Journal of the European Union*.
15. Goodchild, M. F. (2007). Citizens as sensors: the world of volunteered geography. *GeoJournal*, 69(4), 211-221.
16. Krieger, K., & Demuth, J. L. (2014). Critical infrastructure and climate change: Identifying threats and strategies for adaptation. *Environment: Science and Policy for Sustainable Development*, 56(4), 44-52.
17. Openshaw, S. (1983). The Modifiable Areal Unit Problem. *GeoBooks*.
18. Zerger, A., & Wealands, S. (2004). Beyond modelling: linking models with GIS for flood risk management. *Natural Hazards*, 33(2), 191-208.

Referencias Bibliográficas

1. Brzezinski, Z. (2004). *The Grand Chessboard: American Primacy and Its Geostrategic Imperatives*. Basic Books.
2. Kaplan, R. D. (2012). *The Revenge of Geography: What the Map Tells Us About Coming Conflicts and the Battle Against
1. Grau, L. W., & Gress, M. A. (2002). *The Soviet-Afghan War: How a Superpower Fought and Lost*. University Press of Kansas.
2. McMichael, S. (2009). Terrain, Tactics and Technology in the Afghan War. *The RUSI Journal*, 154(4), 60-64.
3. Pollack, K. M. (2002). *Arabs at War: Military Effectiveness, 1948-1991*. University of Nebraska Press.
4. Boot, M. (2006). *War Made New: Technology, Warfare, and the Course of History, 1500 to Today*. Gotham Books.
5. Thompson, L. (2011). *U.S. Military Bases in the Middle East*. Oxford University Press.
6. Friedman, G. (2009). *The Next 100 Years: A Forecast for the 21st Century*. Anchor Books.
7. House, J. M. (2001). *Combined Arms Warfare in the Twentieth Century*. University Press of Kansas.
8. Keegan, J. (1991). *The Price of Admiralty: The Evolution of Naval Warfare*. Penguin Books.
9. Batty, M., & Longley, P. (1994). *Fractal Cities: A Geometry of Form and Function*. Academic Press.
10. DeMers, M. N. (2009). *Fundamentals of Geographic Information Systems*. Wiley.
11. Goodchild, M. F., & Janelle, D. G. (2004). *Spatially Integrated Social Science*. Oxford University Press.
12. Jensen, J. R. (2007). *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice Hall.
13. Lillesand, T. M., & Kiefer, R. W. (2000). *Remote Sensing and Image Interpretation*. Wiley.
14. Lacher, A., & Peterson, S. (2011). *Unmanned Aircraft Systems: A Historical Perspective*. American Institute of Aeronautics and Astronautics.
15. Hough, F. O. (1958). *The Assault on Peleliu*. United States Marine Corps.
16. Morison, S. E. (1951). *The Two-Ocean War: A Short History of the United States Navy in the Second World War*. Little, Brown and Company.
17. Prados, J. (2009). *Vietnam: The History of an Unwinnable War, 1945-1975*. University Press of Kansas.
18. Summers, H. G. (1982). *On Strategy: A Critical Analysis of the Vietnam War*.